

DOI: 10.19783/j.cnki.pspc.250635

基于多维数据融合和 CNN-BiLSTM 联合优化的 超短期风电功率预测

马艺玮, 刘智强, 邹密, 陈俊生, 严冬

(重庆邮电大学自动化学院/工业互联网学院, 重庆 400065)

摘要: 风电功率的精准预测是提升风电并网稳定性和风电场经济收入的一项有效解决方案。针对自然气象特征的复杂性与随机性导致风电功率难以精准预测的突出问题, 提出了一种综合考虑多维数据融合和卷积双向长短期记忆神经网络(convolutional neural network-bidirectional long short-term memory network, CNN-BiLSTM)联合优化的超短期风电功率预测方法。该方法主要包括两个阶段。首先, 在输入数据处理阶段, 通过将主成分分析(principal component analysis, PCA)选择的关键气象因素与最优变分模态分解(optimal variational mode decomposition, OVMD)得到的风电功率固有模态分量相结合, 构建一种新的多维特征数据以提高预测模型的准确性。其次, 在预测模型的联合优化阶段, 先构建了一个集成卷积神经网络(convolutional neural network, CNN)和 BiLSTM 的串联式结构预测组合模型, 再通过使用红嘴蓝喜鹊优化算法(red-billed blue magpie optimizer, RBMO)对 CNN 和 BiLSTM 模型进行联合优化, 从而充分发挥二者之间互补优势来提高预测精度。通过对风电功率预测的比较分析, 结果充分证明所提出的 PCA-OVMD-RBMO-(CNN-BiLSTM)预测方法比其他对比预测方法具有更高的预测精度。

关键词: 风电功率预测; 主成分分析; 最优变分模态分解; 卷积神经网络; 双向长短期神经网络

Ultra-short-term wind power forecasting based on multidimensional data fusion and joint optimization of CNN-BiLSTM

MA Yiwei, LIU Zhiqiang, ZOU Mi, CHEN Junsheng, YAN Dong

(School of Automation/School of Industrial Internet, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Accurate wind power forecasting is an effective means of improving the stability of wind power grid integration and the economic performance of wind farms. Aiming at the prominent challenge that the complexity and randomness of natural meteorological characteristics make wind power difficult to predict accurately, this paper proposes an ultra-short-term wind power forecasting method based on multidimensional data fusion and the joint optimization of a convolutional neural network-bidirectional long short-term memory network (CNN-BiLSTM). The method consists of two main phases. First, in the input data processing phase, a new multidimensional feature data is constructed to improve the accuracy of the prediction model, which combines the key meteorological factors selected by principal component analysis (PCA) with the wind power intrinsic modal components obtained via optimized variational mode decomposition (OVMD). Second, in the joint optimization phase of the forecasting model, a cascaded hybrid forecasting model integrating CNN and BiLSTM is constructed, and the red-billed blue magpie optimizer (RBMO) is employed to jointly optimize the CNN and BiLSTM models. This allows the complementary advantages of the two models to be fully exploited, further enhancing forecasting accuracy. Comparative analyses of wind power forecasting results demonstrate that the proposed PCA-OVMD-RBMO-(CNN-BiLSTM) method achieves higher prediction accuracy than other benchmark forecasting methods.

This work is supported by the National Natural Science Foundation of China (No. 61703068).

Key words: wind power forecasting; principal component analysis; optimal variational mode decomposition; convolutional neural network; bidirectional long short-term memory network

基金项目: 国家自然科学基金项目资助(61703068); 重庆市教育委员会科学技术研究项目资助(KJQN202504202); 重庆市研究生科研创新项目资助(CYS23468, CYS23469)

0 引言

在“双碳”目标背景下, 风力发电因其特有的经济成本低、清洁环保等优点而取得了飞速的发展。然而, 由于受外部气象因素的影响和制约, 风电功率具有随机波动性和不稳定性等非线性特点, 对其并网以及电网系统的运行调度均带来了显著挑战^[1-2]。由于风电功率的预测精度与预测时长呈一种近似反比关系, 预测时间越长则会造成预测精度越低^[3]。因此, 研究开发准确可靠的超短期风电功率预测模型对于提高风电并网效能和优化电网调度效益提供了一种切实有效的解决方案^[4-6]。

随着人工智能技术的不断进步与发展, 各种深度学习模型如卷积神经网络(convolutional neural network, CNN)^[7]、长短期记忆网络(long short term memory, LSTM)^[8-9]和门控循环单元(gated recurrent unit, GRU)^[10]等已成为提高超短期风电功率预测性能的首选方法, 这是因为其具有强大的非线性学习能力和适应性, 能有效克服传统物理模型和统计模型面临的预测精度低问题。然而, 随着研究的不断深入, 发现在处理复杂多变的高维时序数据时, 单一神经网络模型在预测精度和泛化能力上存在明显的技术局限性, 而混合神经网络模型则展现出更优的性能。为了更好地提高预测精度, 文献[11]提出了 CNN-LSTM 组合模型, 充分发挥 CNN 的局部特征提取优势和 LSTM 的时间序列特征提取优势, 以提高短期风电功率预测性能。文献[12]提出了结合 CNN 和 GRU 神经网络的超短期风电功率预测组合模型, 实验结果表明组合预测模型相比单一预测模型具有更高的预测精度和鲁棒性。以上采用神经网络模型来同时处理复杂多变的风电功率和风速等高维气象数据的特征提取方法, 会存在难以准确捕捉到更深层次的时序特征而降低预测模型精度等突出问题^[13]。

与基于神经网络的特征提取方法相比, 信号分解法能够将复杂多变的风电功率数据分解为多个平稳的固有模态子序列, 有助于神经网络模型更精准地学习不同频率特征, 从而获得更高的预测精度。文献[14]提出了基于 VMD-LSTM 的风电功率预测组合模型, 选用变分模态分解(variational mode decomposition, VMD)将风电功率序列分解为长期分量、波动分量和随机分量来提高 LSTM 预测模型的精度。然而, 在该方法中 VMD 的参数设置是基于经验而非最优的, 可能难以获得更高的预测准确性。文献[15]提出了一种同时考虑风电功率和气象环境因素的 LTBDO-VMD-LTDBO-LSTM 预测组合模型, 分别使用改进蜣螂优化算法(logistic-t-dung

beetle optimizer, LTDBO)对 VMD 的分解层数、惩罚因子及 LSTM 的神经元个数等超参数进行优化, 有效提高了风电功率预测的精度。此外, 文献[16]采用麻雀搜索算法(sparrow search algorithm, SSA)来优化 VMD 参数, 提高了 LSTM 神经网络模型的预测精度。然而, 上述文献都是将风电功率与随机选取的部分关键气象因子(如风速等)作为输入数据, 而没有对众多的气象特征因子进行降维处理以降低信息的冗余性和相关性, 从而限制了预测精度的进一步提升。

基于以上分析, 为了获取更精准的超短期风电功率预测结果, 以有效提升风电场经济效益并保障电网稳定运行, 本文提出一种新的集风电功率与关键气象因子的多维数据融合、卷积双向长短期记忆神经网络(convolutional neural network-bidirectional long short-term memory network, CNN-BiLSTM)组合模型联合优化于一体的超短期风电功率预测方法。该方法主要包含两部分内容: 1) 构建了包含基于主成分分析(principal component analysis, PCA)的关键气象特征, 与基于最优变分模态分解(optimal variational mode decomposition, OVMD)的风电功率模态分量特征的气象-功率多维特征数据处理模块, 以改善输入数据的分布特性来提高预测模型性能。2) 构建了一种融合 CNN 和 BiLSTM 的组合模型(CNN-BiLSTM), 并选用红嘴蓝喜鹊优化算法(red-billed blue magpie optimizer, RBMO)对其同步联合优化, 充分发挥 CNN 的特征提取优势和 BiLSTM 的时序数据处理优势, 以提高超短期风电功率预测的准确性。为验证所提方法的优越性, 选取国内新疆某风电场的实测数据对所提方法进行详细比较分析和验证。

1 基于气象-功率多维数据融合的数据处理

为了使预测模型更好地学习数据的分布特征, 本文构建一种如图 1 所示的基于气象-功率多维数据融合的输入数据处理方法, 提高超短期风电功率预测的精度和泛化能力。

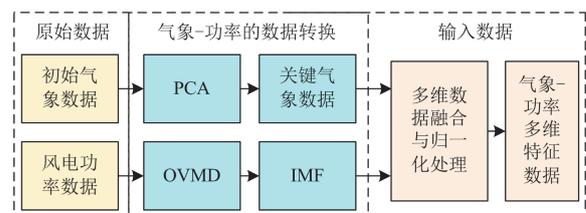


图 1 基于气象-功率多维数据融合的输入数据处理方法
Fig. 1 Input data processing method integrating meteorology-power multidimensional data fusion

1.1 基于 PCA 的关键气象因子提取

影响风电功率预测的气象因子有很多,如风速、风向、气压和密度等,不可避免地会造成不同因子之间的信息冗余,进而会对风电功率预测准确性带来不良影响。因此,本文选取经典数据降维法中的主成分分析法(principal component analysis, PCA)^[17-18]来提取关键气象因子,消除过多参数因子之间的冗余信息,实现对原始风电功率气象因子的降维。基于 PCA 的关键风电气象因子提取主要是使用式(1)来计算前 M 个主成分的累积方差贡献率 η_M , 且当其超过一定的阈值(通常为 90%以上)时,则认为前 M 个主成分可以充分表示原始风电气象因子的全部信息,并通过式(2)来获得该 M 个新的气象因子。

$$\eta_M = \sum_{i=1}^M \lambda_i / \sum_{i=1}^D \lambda_i \quad (1)$$

$$\begin{cases} y_1 = e_{11}x_1 + e_{12}x_2 + \dots + e_{1D}x_D \\ y_2 = e_{21}x_1 + e_{22}x_2 + \dots + e_{2D}x_D \\ \vdots \\ y_M = e_{M1}x_1 + e_{M2}x_2 + \dots + e_{MD}x_D \end{cases} \quad (2)$$

式中: y_M 为得到的第 M 个新变量; λ_i 为相关系数矩阵中主成分对应的第 i 个特征值; D 为原始气象因子的维数; e_{MD} 为第 M 个新变量对第 D 个原始变量的权重; x_D 为原始数据的第 D 个变量。

1.2 基于 OVMD 的风电功率模态分解

VMD 作为一种典型的信号时频分析方法,具有对复杂数据分解精度高、抗噪声干扰能力强等显著优势^[19-20]。因此,近年来许多学者都选用 VMD 将复杂非线性的风电功率时序数据分解为多个窄带模态分量,并将其作为预测模型的输入数据。然而,研究表明 VMD 性能对模态分解总数 K 和步长参数 ε 特别敏感,如果参数设置不当,会导致过分解或欠分解等问题,进而影响预测精度。为此,本文采用最优变分模态分解(optimal variational mode decomposition, OVMD)^[21]对风电功率时序数据进行模态分解,其最优参数的确定方式如下所述。

1) 模态分解总数 K : 使用中心频率法确定数量。

2) 更新步长参数 ε : 通过残差评估指数(I_{REI})的最小化来确定,如式(3)所示。

$$I_{\text{REI}} = \min \frac{1}{N_{\text{IMF}}} \sum_{\alpha=1}^{N_{\text{IMF}}} \left[\sum_{\kappa=1}^K u_{\kappa} - S \right] \quad (3)$$

式中: N_{IMF} 为每个模态分量的样本数量; α 表示每个模态分量的第 α 个样本; u_{κ} 为第 κ 个模态分量; S 为原始信号。

一旦确定 OVMD 的最优参数,风电功率时序

数据经 OVMD 分解得到的固有模态函数(intrinsic mode function, IMF)可由式(4)表示。

$$\mathbf{F}_{\text{IMF}} = [\mathbf{F}_1, \mathbf{F}_2, \dots, \mathbf{F}_K] = \begin{bmatrix} u_{1,1} & u_{2,1} & \dots & u_{K,1} \\ u_{1,2} & u_{2,2} & \dots & u_{K,2} \\ \vdots & \vdots & & \vdots \\ u_{1,l} & u_{2,l} & \dots & u_{K,l} \end{bmatrix} \quad (4)$$

式中: \mathbf{F}_{IMF} 为风电功率固有模态函数; \mathbf{F}_K 为风电功率第 K 个模态分量; $u_{K,l}$ 为 $l \times K$ 矩阵中的元素。

1.3 兼顾气象-功率多维数据融合的输入数据构建

在风电功率预测中需计及功率、风速、风向等多种变量,不同变量具有不同的量纲,且数值大小差异较大。为此,需要先采用式(5)对气象数据进行反归一化处理,再使用式(6)对其与经 OVMD 分解的风电功率模态分量一起完成离差归一化处理。

$$X'_{NW_M} = X''_{NW_M} \times (X_{NW_M}^{\max} - X_{NW_M}^{\min}) + X_{NW_M}^{\min} \quad (5)$$

$$X_j^* = \frac{X'_j - X'_{\min}}{X'_{\max} - X'_{\min}} \quad (6)$$

式中: X'_{NW_M} 为第 M 个关键气象因子经反归一化后的数值; X''_{NW_M} 为经 PCA 提取出的第 M 个关键气象因子的数值; $X_{NW_M}^{\max}$ 、 $X_{NW_M}^{\min}$ 分别为第 M 个关键气象因子的最大和最小数值; X'_j 为离差归一化前的数值; X_j^* 为离差归一化后的数值; X'_{\max} 、 X'_{\min} 分别为离差归一化的最大和最小数值。

兼顾气象-功率的多维数据融合不仅包含基于 PCA 提取的关键气象因子特征,还包含基于 OVMD 的风电功率模态分量特征。因此,每一个风电功率模态分量数据均对应其相应的关键气象因子特征数据,二者共同作为 CNN-BiLSTM 组合模型的输入,其数学模型如式(7)所示。

$$\mathbf{X}_j^{\text{inp}} = [X_{F_1,j}^*, \dots, X_{F_K,j}^*, X_{NW_1,j}^*, \dots, X_{NW_M,j}^*] \quad (7)$$

式中: $\mathbf{X}_j^{\text{inp}}$ 为输入数据; $X_{F_K,j}^*$ 为经归一化后的第 j 个输入数据中的第 K 个风电功率模态分量; $X_{NW_M,j}^*$ 为经过归一化后的第 j 个输入数据中的第 M 个关键气象特征数据。

2 CNN-BiLSTM 模型联合优化

CNN-BiLSTM 模型结合了 CNN 和 BiLSTM 的优势,因其良好的互补性已被广泛应用于交通、电力和金融等领域的时序预测问题,但在模型复杂度和参数调优等方面仍面临着突出的挑战。为此,文中分别构建了 CNN-BiLSTM 串联架构模型、基于 RBMO 算法的模型参数优化策略,以实现模型强大

的功能、有效提高模型的预测性能和可解释性。

2.1 CNN-BiLSTM 串联架构模型

CNN-BiLSTM 串联架构模型是指将 CNN 与 BiLSTM 按顺序串联连接的一种组合模型, 如图 2 所示。其基本原理是: 先将输入数据送入 CNN 模块, 由卷积层和池化层提取风电时序数据的局部特征, 生成特征图, 输出一维特征向量给 BiLSTM 模块^[22-24], 然后 BiLSTM 对 CNN 提取的特征序列进行双向的时序依赖捕捉处理, 将前向和后向的特征信息进行融合, 生成更全面的特征表示, 从而实现更精准的超短期风电功率预测。

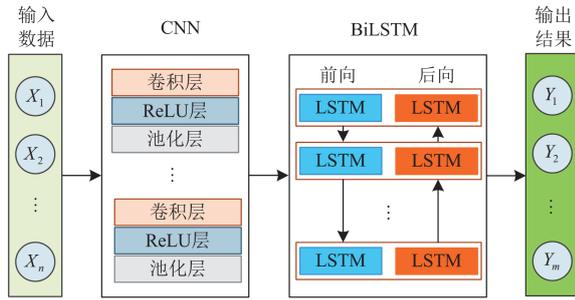


图 2 CNN-BiLSTM 串联架构模型

Fig. 2 CNN-BiLSTM serial architecture model

CNN-BiLSTM 模型的基本数理模型如下。

1) CNN 核心在于卷积操作, 其计算公式如式(8)所示。

$$y_q^p = f(x \cdot w + B) \quad (8)$$

式中: y_q^p 为第 p 个卷积层中第 q 个卷积核的输出值; f 为激活函数; x 为输入数据序列; w 为卷积核的权重; B 为偏置量。

2) BiLSTM 的核心在于遗忘门 $f_{r,t}$ 、输入门 $i_{r,t}$ 和输出门 $o_{r,t}$ 的操作, 相应的数学公式分别如式(9)一式(11)所示。

$$f_{r,t} = \sigma(\omega_{r,fx}x_t + \omega_{r,fh}h_{r,t-1} + b_{r,f}) \quad (9)$$

$$i_{r,t} = \sigma(\omega_{r,ix}x_t + \omega_{r,ih}h_{r,t-1} + b_{r,i}) \quad (10)$$

$$o_{r,t} = \sigma(\omega_{r,ox}x_t + \omega_{r,oh}h_{r,t-1} + b_{r,o}) \quad (11)$$

式中: σ 为 Sigmoid 函数; x_t 为 t 时刻的输入数据序列; $\omega_{r,fx}$ 、 $\omega_{r,ix}$ 、 $\omega_{r,ox}$ 分别为第 r 个 LSTM 中遗忘门、输入门、输出门输入数据对应的权重; $\omega_{r,fh}$ 、 $\omega_{r,ih}$ 、 $\omega_{r,oh}$ 分别为第 r 个 LSTM 中遗忘门、输入门、输出门隐藏层状态对应的权重; $h_{r,t-1}$ 为第 r 个 LSTM 中隐藏层状态; $b_{r,f}$ 、 $b_{r,i}$ 、 $b_{r,o}$ 分别为第 r 个 LSTM 中遗忘门、输入门、输出门中的偏置。

2.2 基于 RBMO 的 CNN-BiLSTM 参数优化

由于 CNN-BiLSTM 组合模型存在参数众多且

参数调优复杂、计算资源消耗大等局限性, 故选取具有优异收敛性和高效性的 RBMO 算法^[25]对 CNN-BiLSTM 模型进行参数调优。基于 RBMO 的 CNN-BiLSTM 模型参数调优流程如图 3 所示。首先, 将 CNN 和 BiLSTM 模型的学习率、卷积核个数、隐藏层神经元个数等重要参数设定为红嘴蓝喜鹊个体的参数, 并选取 BiLSTM 神经网络模型的平均绝对误差(mean absolute error, MAE)作为 RBMO 的适应度函数。然后, 根据 RBMO 优化算法的原理, 先通过式(12)完成种群初始化, 产生 RBMO 的初始搜索代理, 再依次通过模拟红嘴蓝喜鹊的社会行为, 即式(13)所示的搜寻食物、式(14)和式(15)所示的攻击猎物、式(16)所示的食物储存, 来获得最优参数值并赋予 CNN-BiLSTM 模型进行训练、测试和预测。

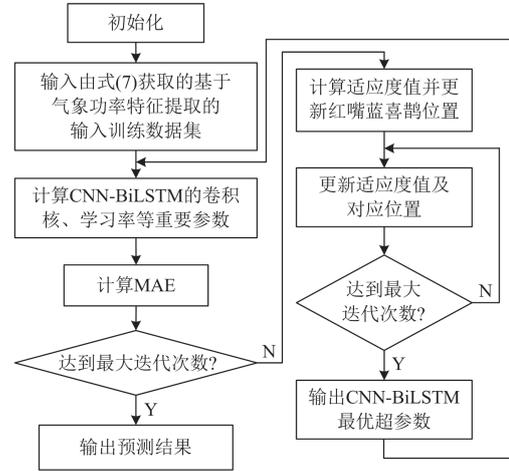


图 3 基于 RBMO 的 CNN-BiLSTM 联合优化流程

Fig. 3 CNN-BiLSTM joint optimization process based on RBMO

$$X_{i,j} = (b_u - b_l) \times R_1 + b_l \quad (12)$$

$$X_i(\tau+1) = X_i(\tau) + \left(\frac{1}{\rho} \sum_{m=1}^{\rho} X_m(\tau) - X_{rs}(\tau) \right) \times R_2 \quad (13)$$

$$X_i(\tau+1) = X_i(\tau) + C_F \times \left(\frac{1}{\rho} \sum_{m=1}^{\rho} X_m(\tau) - X_i(\tau) \right) \times R_n \quad (14)$$

$$C_F = (1 - \tau/T)^{2 \times \tau/T} \quad (15)$$

$$X_i(\tau+1) = \begin{cases} X_i(\tau), & \text{if } F_{i,\text{old}} > F_{i,\text{new}} \\ X_i(\tau+1), & \text{else} \end{cases} \quad (16)$$

式中: $X_{i,j}$ 为第 i 个红嘴蓝喜鹊在第 j 维的位置; b_u 、 b_l 分别为问题的上界和下界; R_1 、 R_2 均为随机数, 取值范围为 $[0,1]$; $X_i(\tau)$ 、 $X_i(\tau+1)$ 分别为第 i 个个体在第 τ 次和第 $\tau+1$ 次迭代时的搜索代理位置; ρ 为随机选择的群体中红嘴蓝喜鹊的数量; $X_m(\tau)$ 为

随机选取的第 m 个个体； $X_{rs}(\tau)$ 为当前迭代中随机选取的搜索代理； $X_f(\tau)$ 为第 τ 次迭代时食物的位置； C_f 为控制因子； T 为最大迭代次数； R_n 为服从标准正态分布的随机数； $F_{i,old}$ 和 $F_{i,new}$ 分别为第 i 个红嘴蓝喜鹊位置更新前和更新后的适应度值。

3 CNN-BiLSTM 模型联合优化

3.1 数据来源

为验证本文所提的超短期风电功率预测方法，选取装机容量为 200 MW 的新疆某风电场 2021 年 365 天的历史数据，其中气象特征数据通过数字天气预报(numerical weather prediction, NWP)获得，如测风塔高度分别为 10 m、30 m 和 50 m 的风速和风向、温度、气压、湿度、空气密度等。此外，输入数据按照 8:2 的比例随机拆分为训练集和测试集数据，且每个数据集的时间分辨率均为 15 min。

3.2 性能评估指标

本文选用平均绝对误差(mean squared error, MAE)、均方误差(mean squared error, MSE)、均方根误差(root mean square error, RMSE)、模型拟合优度(model goodness of fit, MGF)和决定系数(R^2) 5 个指标^[26-29]来评估预测模型的性能，计算公式分别如式(17)–(21)所示。此外，建立了改善率指标 k_{SM} 来量化所提方法相对于其他方法的优越性程度，如式(22)所示。

$$E_{MAE} = \frac{1}{N} \sum_{z=1}^N |P_z - \hat{P}_z| \quad (17)$$

$$E_{MSE} = \frac{1}{N} \sum_{z=1}^N (P_z - \hat{P}_z)^2 \quad (18)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{z=1}^N (P_z - \hat{P}_z)^2} \quad (19)$$

$$E_{MGF} = 1 - \sqrt{\frac{\sum_{z=1}^N (P_z - \hat{P}_z)^2}{\sum_{z=1}^N P_z^2}} \quad (20)$$

$$R^2 = 1 - \frac{\sum_{z=1}^N (P_z - \hat{P}_z)^2}{\sum_{z=1}^N (P_z - \bar{P})^2} \quad (21)$$

$$k_{SM} = \frac{E_{cm} - E_{pm}}{E_{pm}} \times \zeta \times 100\% \quad (22)$$

式中： P_z 和 \hat{P}_z 分别为第 z 个采样点风电功率的实际值和预测值； \bar{P} 为风电功率实际值的平均值； N 为样本总数量； E_{pm} 和 E_{cm} 分别为所提预测方法和对比预测方法在某个评价指标的得分； ζ 为系数，取值为 1 或 -1，其中 1 代表指标越小越好，-1 代表指标越大越好。

3.3 输入数据处理

3.3.1 基于 PCA 的气象特征提取

原始风电相关数据包含风速、风向、温度、气压和湿度等 11 种不同气象特征。这些数据之间存在多余、不必要的重复信息；为了更高效地处理和分析数据，消除冗余特征，降低数据的复杂性，采用 PCA 进行数据降维，各主成分的方差贡献率以及前 4 个主成分的累积方差贡献率如图 4 所示。

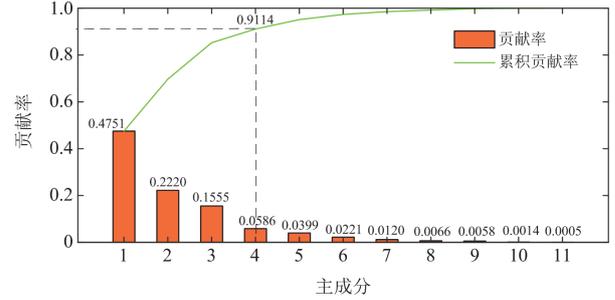


图 4 主成分的方差贡献率

Fig. 4 Variance contribution rate of principal components

由图 4 可以看出，前 4 个主成分累计贡献率已达 91.14%，已超过经验阈值 90%。因此，选取这 4 个主成分能基本代表原先的 11 维气象特征，以较少的维度捕获原始数据中绝大部分的方差信息，显著降低了原始数据的冗余性和复杂性。这 4 个主成分与原始气象特征的相关性热力图如图 5 所示。

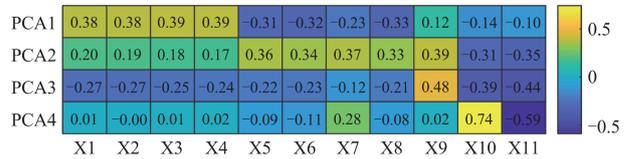


图 5 前 4 个主成分与原始气象特征的相关系数

Fig. 5 Correlation coefficient between the first 4 principal components and original meteorological characteristics

3.3.2 基于 OVMD 的风电功率特征提取

选用 OVMD 对风电功率进行最优模态分解，提取表征原始序列变化趋势的主导分量，得到最优分解数为 6，惩罚因子为 1061.51，OVMD 分解风电功率的模态分量结果如图 6 所示。

3.4 预测结果与分析

3.4.1 基于 RBMO 的 CNN-BiLSTM 参数寻优

采用 RBMO 算法搜寻 CNN-BiLSTM 模型的最优参数值，关键参数分别为学习率、第一层卷积核个数、第二层卷积核个数和 BiLSTM 隐藏层神经元数等。RBMO 算法、CNN 和 BiLSTM 的关键参数预设值如表 1 所示。CNN-BiLSTM 模型参数如表 2 所示。

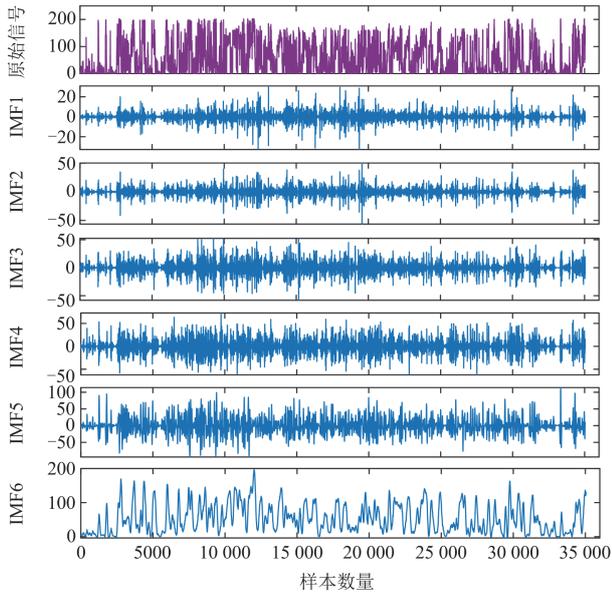


图 6 OVMMD 分解风电功率的本征模态分量

Fig. 6 IMFs of wind power decomposed by OVMMD

表 1 模型参数范围与最优参数

Table 1 Parameter range and optimal parameters

参数	寻优范围	最优值
学习率	[0.001,0.1]	0.001
第一层卷积核个数	[4,32]	24
第二层卷积核个数	[4,32]	20
隐藏层神经元数	[4,128]	30
种群数量	20	—
迭代次数	30	—

表 3 实验模型说明

Table 3 Experimental model description

编号	模型	说明
M1	LSTM	气象和功率都无处理
M2	BiLSTM	气象和功率都无处理
M3	Transformer	气象和功率都无处理
M4	VMD-CNN-BiLSTM	考虑全部气象和基于 VMD 的功率特征, 但模型无优化
M5	OVMMD-CNN-BiLSTM	考虑全部气象和基于 OVMMD 的功率特征, 但模型无优化
M6	PCA-OVMMD-CNN-BiLSTM	考虑气象-功率特征提取, 但 CNN-BiLSTM 无优化
M7	PCA-OVMMD-(RBMO-CNN)-(RBMO-BiLSTM)	考虑气象-功率多维数据融合以及 CNN 与 BiLSTM 各自优化
M8	PCA-OVMMD-SSA-(CNN-BiLSTM)	考虑气象-功率多维数据融合和基于 SSA 的 CNN-BiLSTM 联合优化
M9	PCA-OVMMD-RBMO-(CNN-BiLSTM)	考虑气象-功率多维数据融合和基于 RBMO 的 CNN-BiLSTM 联合优化

根据图 7 和表 4 的结果可知, 与其他方法相比, 本文提出的 PCA-OVMMD-RBMO-(CNN-BiLSTM) 预测方法的预测结果能更准确地遵循实际风电功率曲线, 具有最小的预测偏差和最高的精度。该结论也可以从表 4 列出的各项评价指标得分(包括 MAE、MSE、RMSE、MGF 和 R^2)中得到印证, 表明所提

表 2 CNN-BiLSTM 模型参数

Table 2 Parameters of CNN-BiLSTM model

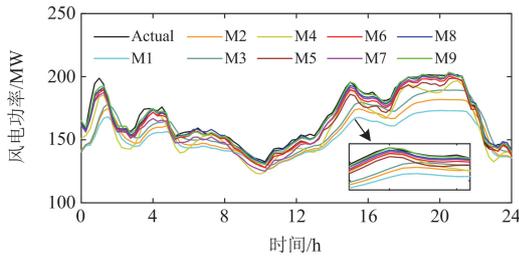
模块	层类型	输出维度	核大小	步长
CNN	输入层	50	—	—
	卷积层 1	50×24	5	1
	ReLU	50×24	—	—
	最大池化层 1	25×24	2	2
	卷积层 2	25×20	3	1
	ReLU	25×20	—	—
BiLSTM	最大池化层 2	13×20	2	2
	Flatten	260	—	—
	BiLSTM	60	—	—
	Dropout	60	—	—
	FC	1	—	—

3.4.2 实验结果分析与对比

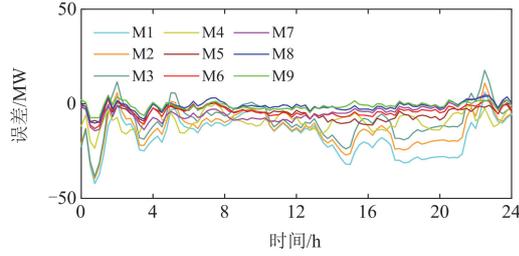
本文所提超短期风电功率预测方法采用单步预测方式, 选取预测时刻前 10 个时间步的历史数据作为输入数据, 每一个时间步的时间间隔为 15 min。每一个时间步的历史数据包含归一化后的 4 个关键气象因素特征和 1 个风电功率模态分量特征。本文所提基于气象-功率多维数据融合和 CNN-BiLSTM 联合优化的超短期风电功率预测方法记为“PCA-OVMMD-RBMO-(CNN-BiLSTM)”(编号 M9), 分别与其他 8 种不同方法进行对比实验, 以验证其有效性与优越性。各种预测方法的编号、模型及其说明等如表 3 所示, 相应的风电功率预测仿真结果及预测偏差如图 7 所示, 各方法的 5 个预测性能评价指标值的比较结果如表 4 所示。

PCA-OVMMD-RBMO-(CNN-BiLSTM) 模型在超短期风电功率预测中表现最优。

为更充分地验证本文所提方法(M9)相对于其他模型的优越性, 表 5 进一步对比了各模型在不同预测性能评价指标上的改善率。分析结果表明, 所提方法(M9)相比其他预测方法均具有明显的性能提



(a) 预测结果



(b) 预测偏差

图 7 不同方法的预测结果比较

Fig. 7 Prediction results comparison of different methods

表 4 不同方法的性能评价比较

Table 4 Evaluation comparison of different methods

模型	MAE/MW	MSE/MW ²	RMSE/MW	MGF	R ²
M1	8.7747	154.4046	12.4260	0.8139	0.9432
M2	8.1673	144.7027	12.0292	0.8199	0.9468
M3	7.5622	155.3994	12.4659	0.8133	0.9429
M4	5.7942	75.7360	8.7026	0.8697	0.9721
M5	3.7075	23.9637	4.8953	0.9267	0.9912
M6	3.0716	19.9010	4.4611	0.9332	0.9926
M7	2.9819	17.3663	4.1673	0.9376	0.9936
M8	2.5284	13.9909	3.7404	0.9440	0.9948
M9	2.2378	12.1876	3.4911	0.9477	0.9955

升。如在 k_{MAE} 指标上有 12.99%~292.11% 的改善率, 在 k_{MSE} 指标上有 14.80%~1166.90% 的改善率, 在 k_{RMSE} 指标上有 7.14%~255.93% 的改善率, 在 k_{MGF} 指标上有 0.39%~14.12% 的改善率, 在 k_{R^2} 指标上有 0.07%~5.25% 的改善率。

此外, 为了探究所提预测模型的计算时间和算法稳定性, 在相同的训练集和测试集上对所提出的 PCA-OVMD-RBMO-(CNN-BiLSTM) 模型进行 20 次独立训练和预测, 得到平均训练时间为 1068.6636 s, 平均单次预测时间为 2.6230 ms, 模型计算速度快, 能较好地满足超短期风电功率预测的实时性需求。表 6 给出了该预测模型在评价指标上的波动标准差, 其中, MAE 的标准差为 0.0921 MW, MSE 的标准差为 0.5234 MW², RMSE 的标准差为 0.0322 MW, MGF 的标准差为 0.0080, R² 的标准差为 0.0012。各指标波动均控制在较小范围内, 充分表明本文所

提模型在不同的训练过程中能够保持稳定的性能, 不会因偶然因素而导致预测结果出现较大偏差。

表 5 方法 M9 相比其他方法的改善率

Table 5 Improvement ratio between M9 and other methods

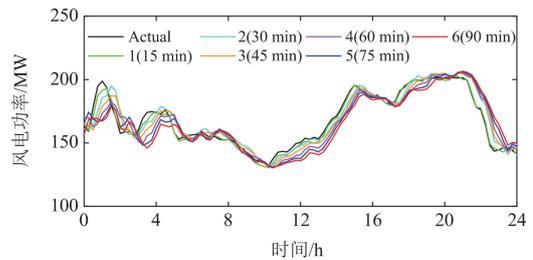
模型	k_{MAE}	k_{MSE}	k_{RMSE}	k_{MGF}	k_{R^2}
M9 vs M1	292.11	1166.90	255.93	14.12	5.25
M9 vs M2	264.97	1087.29	244.57	13.49	4.89
M9 vs M3	237.93	1175.06	257.08	14.18	5.28
M9 vs M4	158.92	521.42	149.28	8.23	2.35
M9 vs M5	65.68	96.62	40.22	2.22	0.43
M9 vs M6	37.26	63.29	27.78	1.53	0.29
M9 vs M7	33.25	42.49	19.37	1.07	0.19
M9 vs M8	12.99	14.80	7.14	0.39	0.07

表 6 所提模型性能评价指标波动标准差

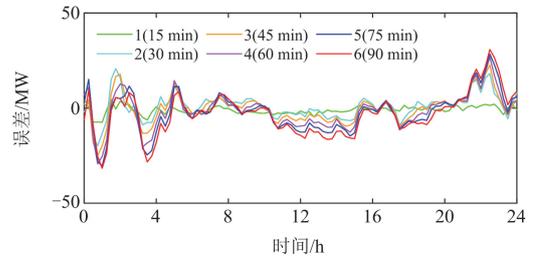
Table 6 Standard deviation of fluctuations in performance evaluation indicators for the proposed model

评价指标	波动标准差
MAE/MW	0.0921
MSE/MW ²	0.5234
RMSE/MW	0.0322
MGF	0.0080
R ²	0.0012

为验证本文所提的 PCA-OVMD-RBMO-(CNN-BiLSTM) 预测方法是否满足超短期风电功率预测的时间要求, 比较分析了从 1 步(15 min)到 6 步(90 min)不同时段的风电功率预测结果, 如图 8 所示。表 7 列出了所提方法在不同时间步下风电功率预测的 MAE、



(a) 预测结果



(b) 预测偏差

图 8 不同时间步长的预测结果比较

Fig. 8 Comparison of prediction results with different time steps

表 7 不同时间步长之间的预测性能比较

Table 7 Comparison of prediction performances between different time steps

步长	MAE/MW	MSE/MW ²	RMSE/MW	MGF	R ²
1 (15 min)	2.2378	12.1876	3.4911	0.9477	0.9955
2 (30 min)	2.6212	17.9261	4.2339	0.9365	0.9934
3 (45 min)	3.0815	25.7672	5.0742	0.9239	0.9905
4 (60 min)	4.1585	46.7436	6.8369	0.8975	0.9828
5 (75 min)	5.1818	71.7563	8.4709	0.8730	0.9736
6 (90 min)	5.7118	85.3155	9.2366	0.8616	0.9686

MSE、RMSE、MGF 和 R^2 等性能指标评估结果。可以清楚获知, 所提预测方法的一次性最大预测时长为 4 步(60 min)时仍具有较好的预测精度, 而当超过 5 步(75 min)时, 模型的 MAE、MSE、RMSE 很大, 且 MGF、 R^2 很小, 预测效果较差。因此, 所提预测方法符合超短期风电功率预测的时间要求, 且预测时间范围越长, 则预测误差越大。

综合上述的预测结果与性能指标可知, 本文提出的基于多维数据融合和 CNN-BiLSTM 联合优化的超短期风电功率预测方法是科学可行的, 具有更优异的预测精准性。下面详细解释所提出的气象-功率多维数据融合、CNN-BiLSTM 模型联合优化以及二者集成在超短期风电功率预测上的影响效果。

1) 基于单一模型的 M1—M3 与基于组合模型的 M4—M9 的性能比较。由表 4 和表 5 可知, 在超短期风电功率预测上, BiLSTM 相较于 LSTM 和 Transformer 模型具有更优的性能, 选取 BiLSTM 模型是较好的选择。但是, 结果也清晰表明, 单一预测模型与组合模型之间具有显著的差距, 这充分说明了单一神经网络模型在处理复杂非线性风电功率时序数据上仍存在明显的不足, 因为复杂高维特征等影响因素会严重影响单一模型泛化能力和预测性能。

2) 基于组合模型的 M6 与 M5、M4 的预测性能比较。由表 4 和表 5 可知, 采用 OVMD 在风电功率特征提取上比 VMD 效果更好, 而将基于 PCA 的气象特征和基于 OVMD 的功率特征相结合的方法 M6, 能够有效地提高风电功率预测精度。

3) 基于组合模型的 M9 与 M6—M8 的预测性能比较。由表 4 和表 5 可知, 在同样采用基于 PCA-OVMD 多维数据特征提取的输入数据预处理的基础上, 本文所提方法 M9 的预测性能最佳, 采用 SSA 对 CNN-BiLSTM 组合模型进行联合优化的方法 M8 次之, 而未对组合模型进行参数优化的方法 M6 预测性能最差。此比较结果也充分说明: ① RBMO 算法相比 SSA 算法能够为 CNN-BiLSTM 模型获得更

优的参数; ② 联合优化是提升 CNN-BiLSTM 组合模型预测性能的一种最有效方法。

4) 一次最大预测时长的比较分析。由图 8 和表 7 可知, 所提预测方法在一次最大预测时长为 4 步(60 min)时仍具有较好的预测精度, 因此可认为该方法符合超短期风电功率预测的时间要求, 且随着预测时间范围的增大, 则误差越大。

4 结论

为了更好地提升超短期风电功率的预测精度, 本文提出了一种基于多维数据融合和 CNN-BiLSTM 联合优化的超短期风电功率预测方法, 主要贡献和结论如下。

1) 基于 PCA 的气象特征和基于 OVMD 的功率特征的多维数据融合, 能够有效地提高预测模型的精度。在同等条件下, 本文所提方法相较于未考虑气象特征的方法, 在 MAE、MSE、RMSE、MGF 和 R^2 等评估指标上均表现出更好的性能。

2) 基于 RMBO 的 CNN-BiLSTM 联合优化方法能够有效提高超短期风电功率的预测精度。与未优化的 CNN-BiLSTM、CNN-RMBO-BiLSTM 预测方法相比, 在 MAE、MSE、RMSE、MGF 和 R^2 等评估指标上均具有明显的提升优势。

3) 将气象-功率多维数据融合处理与基于 RMBO 的 CNN-BiLSTM 联合优化相结合的超短期风电功率预测方法能够显著提高预测精度, 与未进行多维数据融合处理的各种预测模型相比, 该方法在 k_{MAE} 、 k_{MSE} 、 k_{RMSE} 、 k_{MGF} 和 k_{R^2} 等指标上, 改善率分别达到 12.99%~292.11%、14.80%~1166.90%、7.14%~255.93%、0.39%~14.12%和 0.07%~5.25%。

参考文献

- [1] ZHU Ying, ZHANG Yanan, WEI Zhinong. Hierarchical cluster coordination control strategy for large-scale wind power based on model predictive control and improved multi-time-scale active power dispatching[J]. Journal of Modern Power Systems and Clean Energy, 2023, 11(3): 827-839.
- [2] 黄馨仪, 刘明波, 林舜江, 等. 考虑风电不确定性的输电系统鲁棒经济调度分布式算法[J]. 电力系统自动化, 2025, 49(4): 165-177.
HUANG Xinyi, LIU Mingbo, LIN Shunjiang, et al. Distributed algorithm for robust economic dispatch of integrated transmission and distribution system considering wind power uncertainty[J]. Automation of Electric Power Systems, 2025, 49(4): 165-177.
- [3] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习

- 和注意力机制的短期风电功率预测[J]. 电力系统保护与控制, 2024, 52(4): 100-108.
- HU Yuhan, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. Power System Protection and Control, 2024, 52(4): 100-108.
- [4] 杨茂, 张书天, 王勃. 基于因果正则化极限学习机的风电功率短期预测方法[J]. 电力系统保护与控制, 2024, 52(11): 127-136.
- YANG Mao, ZHANG Shutian, WANG Bo. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. Power System Protection and Control, 2024, 52(11): 127-136.
- [5] 刘洋, 伍双喜, 朱誉, 等. 基于 CEEMDAN 和 DBO-GRNN 的风电功率超短期预测[J]. 电力建设, 2024, 45(8): 97-105.
- LIU Yang, WU Shuangxi, ZHU Yu, et al. Ultra-short-term prediction of wind power based on CEEMDAN and DBO-GRNN[J]. Electric Power Construction, 2024, 45(8): 97-105.
- [6] 张中丹, 李加笑, 冯智慧, 等. 基于 RF-TCN-SA 及误差修正的风电功率超短期预测[J]. 电网与清洁能源, 2025, 41(2): 113-119.
- ZHANG Zhongdan, LI Jiaxiao, FENG Zhihui, et al. The ultra-short-term wind power prediction based on RF-TCN-SA and error correction[J]. Power System and Clean Energy, 2025, 41(2): 113-119.
- [7] LIU Jie, SHI Quan, HAN Ruilian, et al. A hybrid GA-PSO-CNN model for ultra-short-term wind power forecasting[J]. Energies, 2021, 14(20).
- [8] PAN Chunyang, WEN Shuli, ZHU Miao, et al. Hedge backpropagation based online LSTM architecture for ultra-short-term wind power forecasting[J]. IEEE Transactions on Power Systems, 2024, 39(2): 4179-4192.
- [9] 高盛, 许沛华, 陈正洪, 等. 基于改进 LSTM 神经网络的风电功率短期预报算法[J]. 南方能源建设, 2024, 11(1): 112-121.
- GAO Sheng, XU Peihua, CHEN Zhenghong, et al. A short-term algorithm based on improved LSTM neural network[J]. Southern Energy Construction, 2024, 11(1): 112-121.
- [10] 柳天虹, 齐胜利, 裔扬, 等. 基于分位数回归的改进权重 GRU 风电功率区间预测[J]. 太阳能学报, 2024, 45(12): 291-298.
- LIU Tianhong, QI Shengli, YI Yang, et al. Improved weighted GRU wind power interval prediction based on quantile regression[J]. Acta Energetica Sinica, 2024, 45(12): 291-298.
- [11] 赵建利, 白格平, 李英俊, 等. 基于 CNN-LSTM 的短期风电功率预测[J]. 自动化仪表, 2020, 41(5): 37-41.
- ZHAO Jianli, BAI Geping, LI Yingjun, et al. Short-term wind power prediction based on CNN-LSTM[J]. Process Automation Instrumentation, 2020, 41(5): 37-41.
- [12] 薛阳, 王琳, 王舒, 等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源, 2019, 37(3): 456-462.
- XUE Yang, WANG Lin, WANG Shu, et al. An ultra-short-term wind power forecasting model combined with CNN and GRU networks[J]. Renewable Energy Resources, 2019, 37(3): 456-462.
- [13] 陈海鹏, 周越豪, 王趁录, 等. 基于改进的 CNN-LSTM 短期风功率预测系统旋转备用经济性分析[J]. 高电压技术, 2022, 48(2): 439-448.
- CHEN Haipeng, ZHOU Yuehao, WANG Chenlu, et al. Economic analysis of system spinning reserve based on improved CNN-LSTM short term wind power prediction[J]. High Voltage Engineering, 2022, 48(2): 439-448.
- [14] HAN Li, ZHANG Rongchang, WANG Xuesong, et al. Multi-step wind power forecast based on VMD-LSTM[J]. IET Renewable Power Generation, 2019, 13(10): 1690-1700.
- [15] 王迪, 傅晓锦, 杜诗琪. 基于自适应 VMD-LSTM 的超短期风电功率预测[J]. 南京信息工程大学学报, 2025, 17(1): 74-87.
- WANG Di, FU Xiaojin, DU Shiqi. Ultra-short-term wind power prediction based on adaptive VMD-LSTM[J]. Journal of Nanjing University of Information Science & Technology, 2025, 17(1): 74-87.
- [16] 高晓芝, 郭旺, 郭英军, 等. 基于 SSA-VMD-LSTM-NKDE 的短期风电功率概率预测[J]. 河北科技大学学报, 2023, 44(4): 323-334.
- GAO Xiaozhi, GUO Wang, GUO Yingjun, et al. Short-term wind power probabilistic forecasting based on SSA-VMD-LSTM-NKDE[J]. Journal of Hebei University of Science and Technology, 2023, 44(4): 323-334.
- [17] 王顺江, 范永鑫, 潘超, 等. 基于主成分约简聚类的优化 ELM 短期风速组合预测[J]. 太阳能学报, 2021, 42(8): 368-373.
- WANG Shunjiang, FAN Yongxin, PAN Chao, et al. Short-term wind speed combined forecasting based on optimized ELM of principal component reduction clustering[J]. Acta Energetica Sinica, 2021, 42(8): 368-373.
- [18] 郑伟宏, 朱峰刚, 王小娟, 等. 基于 PCA-Adaboost-GBDT 的短期风电功率预测[J]. 电气自动化, 2024, 46(4): 80-83.
- ZHENG Hongwei, ZHU Fenggang, WANG Xiaojuan, et al.

- Short-term wind power prediction based on PCA-Adaboost-GBDT[J]. *Electrical Automation*, 2024, 46(4): 80-83.
- [19] ZHANG Gang, XU Benben, LIU Hongchi, et al. Wind power prediction based on variational mode decomposition and feature selection[J]. *Journal of Modern Power Systems and Clean Energy*, 2021, 9(6): 1520-1529.
- [20] 朱菊萍, 魏霞, 谢丽蓉, 等. 基于 VMD 和改进 BiLSTM 的短期风电功率预测[J]. *太阳能学报*, 2024, 45(6): 422-428.
- ZHU Juping, WEI Xia, XIE Lirong, et al. Short-term wind power prediction based on VMD and improved BiLSTM[J]. *Acta Energiac Solaris Sinica*, 2024, 45(6): 422-428.
- [21] LIN Qingcheng, CAI Huiling, LIU Hanwei, et al. A novel ultra-short-term wind power prediction model jointly driven by multiple algorithm optimization and adaptive selection[J]. *Energy*, 2024, 288.
- [22] 陈豪钰, 李振华, 张绍哲, 等. 基于 MHA-CNN-SLSTM 和误差补偿的短期互感器误差预测[J]. *电力系统保护与控制*, 2024, 52(24): 74-84.
- CHEN Haoyu, LI Zhenhua, ZHANG Shaozhe, et al. Short-term transformer error prediction based on MHA-CNN-SLSTM and error compensation[J]. *Power System Protection and Control*, 2024, 52(24): 74-84.
- [23] ZHANG Hao, YI Zhenxiao, KANG Le, et al. A novel supercapacitor degradation prediction using a 1D convolutional neural network and improved informer model[J]. *Protection and Control of Modern Power Systems*, 2024, 9(4): 51-68.
- [24] XIA Shiwei, ZHANG Chenhui, LI Yahan, et al. GCN-LSTM based transient angle stability assessment method for future power systems considering spatial-temporal disturbance response characteristics[J]. *Protection and Control of Modern Power Systems*, 2024, 9(6): 108-121.
- [25] FU Shengwei, LI Ke, HUANG Haisong, et al. Red-billed blue magpie optimizer: a novel metaheuristic algorithm for 2D/3D UAV path planning and engineering design problem[J]. *Artificial Intelligence Review*, 2024, 57: 1-8.
- [26] MA Yiwei, MA Weixing, LI Xingzhen, et al. A two-stage LSTM optimization method for ultrashort term PV power prediction considering major meteorological factors[J]. *IEEE Transactions on Industrial Informatics*, 2025, 21(1): 228-237.
- [27] LI Menglin, YANG Ming, YU Yixiao, et al. Short-term wind power forecast based on continuous conditional random field[J]. *IEEE Transactions on Power Systems*, 2024, 39(1): 2185-2197.
- [28] 卢雪, 董存, 王铮, 等. 低温寒潮天气下的风电短期功率预测技术研究[J]. *电网技术*, 2024, 48(12): 4833-4843.
- LU Xue, DONG Cun, WANG Zheng, et al. Research on short-term wind power forecasting technology under low temperature and cold wave weather[J]. *Power System Technology*, 2024, 48(12): 4833-4843.
- [29] 潘超, 王超, 孙惠, 等. 基于超参数优化和误差修正的 STAGN 超短期风电功率预测[J]. *电力系统保护与控制*, 2025, 53(8): 117-129.
- PAN Chao, WANG Chao, SUN Hui, et al. STAGN ultra-short-term wind power forecasting based on hyperparameter optimization and error correction[J]. *Power System Protection and Control*, 2025, 53(8): 117-129.

收稿日期: 2025-06-10; 修回日期: 2025-08-30

作者简介:

马艺玮(1980—), 女, 通信作者, 博士, 副教授, 研究方向为新型电力系统、智能电网、车电网融合、电力物联网等领域的优化设计、运行控制、人工智能; E-mail: mayw@cqupt.edu.cn

刘智强(2001—), 男, 硕士研究生, 研究方向为电力系统大数据分析、新能源发电预测; E-mail: 519708222@qq.com

邹密(1989—), 男, 博士, 副教授, 研究方向为新型电力系统建模与电力大数据分析。E-mail: zoumi@cqupt.edu.cn

(编辑 魏小丽)