

DOI: 10.19783/j.cnki.pspc.241547

增强的超短期风电功率预测：一种 PatchTST-POA-VMD-iTransformer 混合模型

刘新宇, 潘宇, 王亚辉, 李继方, 杨文静

(华北水利水电大学电气工程学院, 河南 郑州 450045)

摘要: 由于风力发电对天气变化的敏感度高, 风电场输出功率随时间变化的波动大, 传统预测模型难以对风电场输出功率进行准确预测, 也难以对风电预测误差进行有效修正。针对上述问题, 提出了一种 PatchTST-POA-VMD-iTransformer 混合预测模型。首先, 基于斯皮尔曼相关系数法进行天气特征与风电功率相关性量化分析, 完成数据筛选和预处理。然后, 引入 PatchTST 对风电场输出功率进行初步预测, 得到初步预测的功率结果。随后, 采用鹈鹕优化算法(pelican optimization algorithm, POA)优化的变模态分解(variational mode decomposition, VMD)对风电预测误差序列进行分解, 再使用 iTransformer 对分解后的误差序列进行预测。最后, 将已获得的初步功率预测结果与误差序列预测结果相结合, 得到最终的风电功率预测结果。消融实验和对比实验结果表明, 所提模型具有较小的预测误差和较优的泛化能力, 能够有效提升超短期风电功率预测的精度和可靠性。

关键词: 风电功率预测; PatchTST; 鹈鹕优化算法; 变模态分解; iTransformer

Enhanced ultra-short-term wind power forecasting: a PatchTST-POA-VMD-iTransformer hybrid model

LIU Xinyu, PAN Yu, WANG Yahui, LI Jifang, YANG Wenjing

(College of Electrical Engineering, North China University of Water Resources and Electric Power, Zhengzhou 450045, China)

Abstract: Due to the high sensitivity of wind power generation to weather changes, the output power of wind farms fluctuates significantly over time. Traditional prediction models struggle to accurately forecast wind farm output power and effectively correct wind power forecasting errors. To address these issues, a PatchTST-POA-VMD-iTransformer hybrid prediction model is proposed. First, the Spearman's rank correlation coefficient method is employed for quantifying the correlation between weather features and wind power, enabling data screening and preprocessing. Then, PatchTST is introduced for preliminary prediction of wind farm output power, yielding initial power forecasting results. Subsequently, pelican optimization algorithm (POA) optimized variational mode decomposition (VMD) is used to decompose wind power forecasting error sequence, and iTransformer is applied to further predict the decomposed error sequence. Finally, the preliminary power forecasting results are combined with the predicted error sequence to obtain the final wind power forecasting results. Ablation and comparative experiment results demonstrate that the proposed model achieves lower prediction errors and superior generalization ability, effectively improving the accuracy and reliability of ultra-short-term wind power forecasting.

This work is supported by the National Natural Science Foundation of China (No. U1804149).

Key words: wind power forecasting; PatchTST; POA; VMD; iTransformer

0 引言

随着经济的飞速发展, 人类在发展经济的同时,

基金项目: 国家自然科学基金项目资助(U1804149); 河南省高等学校重点科研项目资助(25B120003); 河南省科技攻关项目资助(252102210038)

开始越来越关注低碳环保与环境友好。在此背景下, 中国提出了碳达峰和碳中和战略, 欧盟提出了“Fit for 55”计划。几十年间, 我国风电并网装机容量已跃居世界首位^[1]。风力发电在各国新能源发电领域都起着至关重要的作用, 超短期功率预测对电力市场出清、实时电网运营、风机控制、电能质量研究、负荷跟踪与分配等领域具有重要研究价值与

工程意义^[2-4]。

在风电功率预测领域中, 传统预测方式主要有物理方法、统计方法和回归方法等^[5-6]。目前研究主要集中在长短期记忆网络(long short-term memory, LSTM)^[7-10]、门控循环单元(gated recurrent unit, GRU)^[11-13]等循环神经网络类深度学习模型, 以及 Transformer^[14-15]等注意力机制类深度学习模型。例如文献[7]使用公开数据集验证了 LSTM 在风电功率预测方面的可靠性与实用性, 强调了风电功率预测在城市能源管理系统中的作用。但是, LSTM 等循环神经网络类深度学习模型在超短期风电功率预测中捕捉长距离依赖关系的能力不足, 且存在梯度消失和梯度爆炸等问题。文献[16]提出的注意力机制模块和 Transformer 模型有效缓解了上述问题, 其并行处理数据的能力也提高了模型的训练速度和预测效率。因此, Transformer 模型在风电功率预测领域得到了广泛研究与应用。文献[14]使用 Transformer 模型对中国西北地区的风电场进行功率预测, 得到的改进 Transformer 模型相较于 LSTM, 预测结果的平均绝对百分比误差(mean absolute percentage error, MAPE)最高降低 60.7%。文献[15]在 Transformer 模型的编码器-解码器结构中, 融合交叉注意力与自注意力机制, 可有效提升风电功率预测的精度。但是, 由于风电功率的变化波动大, 其与天气特征的关系及其变化趋势难以准确捕捉。使用单一模型进行预测, 往往会产生系统性误差, 导致出现一定的预测偏差。因此, 需要引入误差修正模型对风电功率预测误差进行修正。

对于风电功率预测的误差修正, 现有研究多以自回归积分滑动平均模型(auto regressive integrated moving average, ARIMA)等统计学方法^[17-18]、随机森林(random forest, RF)等传统机器学习方法^[19-21]和 LSTM 等循环神经网络类深度学习模型^[22-23]为主。文献[17]依据验证集和测试集中风电功率预测值与对应实际值的差值构建误差序列, 再引入 ARIMA 误差修正方法对测试集进行误差修正。结果显示, 误差修正后风电场春季功率预测结果的均方误差(mean squared error, MSE)降低了 24.043%。文献[22]基于 LSTM 模型对风电功率预测结果进行误差修正, 使预测结果的均方根误差(root mean squared error, RMSE)降低了 32.983%。但是, ARIMA 等统计学方法和 RF 等传统机器学习模型对误差序列中的噪声较为敏感, 在处理风电预测误差等高维、大规模数据时, 其性能表现亦有不足。循环神经网络类深度学习方法及传统注意力机制模型在捕捉多元条件与非平稳误差序列间依赖关系方面存在不足, 且对局

部依赖问题的处理能力亦有局限。因此, 引入一个可以有效避免噪声干扰, 且能有效捕捉高维特征数据之间依赖关系的误差修正模型十分重要。

针对上述问题, 为提升超短期风电功率预测的精度和泛化性, 提高误差修正的可靠性与实用性, 本文提出一种 PatchTST-POA-VMD-iTransformer 混合预测模型。引入 PatchTST 模型对超短期风电功率进行初步预测。PatchTST 模型能够将时间序列数据有效切分, 并引入了独立通道设计, 使模型能够有效捕捉长距离依赖关系并提取变量特征。在误差修正模块, 本文引入的 iTransformer 模型凭借其创新性的反转式结构设计, 能够有效捕捉各变量间的关系, 减少噪声干扰; 其应用于变量维度的注意力机制可以使高度相关的变量在交互中获得更大权重, 从而提高模型的学习能力。通过将这两种先进模型进行结合, 不仅提高了风电功率预测的精度, 而且增强了模型的泛化性和鲁棒性。

1 模型原理

1.1 超短期风电功率预测总体框架

本文提出的预测模型框架如图 1 所示。

PatchTST-POA-VMD-iTransformer 模型预测流程如下。

1) 数据处理阶段, 根据斯皮尔曼相关系数对风电场各天气特征进行选择。

2) 模型训练阶段, 基于训练集(含验证集)训练预测模型。首先, 将风电场的天气特征和功率数据输入 PatchTST 模型进行训练; 其次, 将 PatchTST 模型训练集的功率预测结果与真实值相减, 得到误差序列; 最后, 误差序列经过鹈鹕优化算法(pelican optimization algorithm, POA)调参的变模态分解(variational mode decomposition, VMD)后, 将各本征模态函数(intrinsic mode function, IMF)作为真值, 与风电场天气特征一起输入 iTransformer 模型进行训练。

3) 模型测试阶段, 基于测试集评估模型性能。首先, 使用 PatchTST 模型对测试集进行预测, 得到测试集初步预测结果, 即风电功率初步预测结果; 然后, 由于 iTransformer 模型在训练阶段已经学习到误差的规律, 在测试阶段, iTransformer 模型根据训练集的误差序列(经过 POA-VMD 分解得到的各 IMF), 并结合相应天气数据逐段预测各 IMF 在测试集对应时间步上的值, 将这些预测值合并作为测试集的误差修正结果。最后, 将风电功率初步预测结果与误差修正结果对应时间步相加, 作为最终的风电功率预测结果。

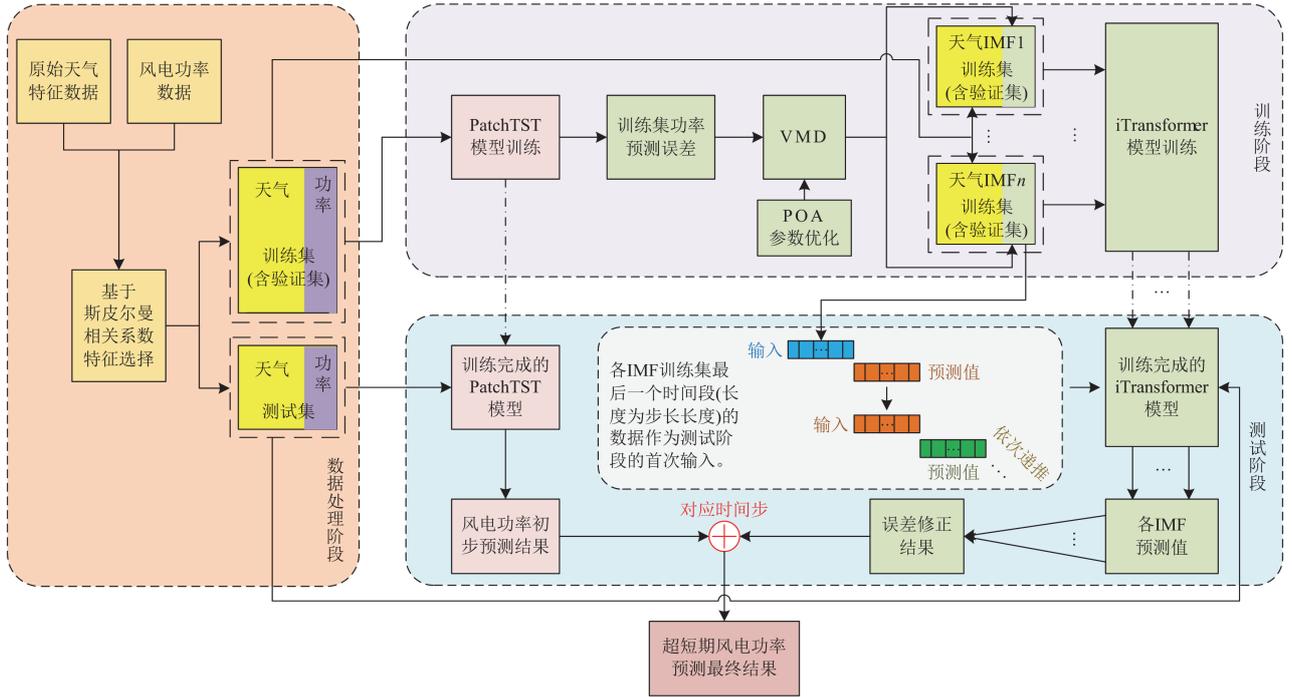


图 1 超短期风电功率预测框架

Fig. 1 Framework of ultra-short-term wind power forecasting

1.2 数据筛选方法

斯皮尔曼相关系数法是一种用于衡量两个变量之间单调关系的非参数统计方法。由于其适用于非线性关系，可以有效捕捉风电功率与天气特征相互作用的复杂关系；其对异常值具有鲁棒性，即使数据嘈杂或不完美，也能够提供可靠的结果；其不需要像机器学习那样进行模型训练，简单便捷，对计算资源的要求较低；其有助于创建清晰且易理解的热力图，以进行可视化分析^[24-25]。因此，本文基于斯皮尔曼相关系数法进行风电功率与天气特征相关性量化分析。

在无重复值时，斯皮尔曼相关系数 ρ 的计算公式如式(1)所示。

$$\rho = 1 - \frac{6 \sum_{b=1}^a d_b^2}{a(a^2 - 1)} \quad (1)$$

式中： d_b 为第 b 组样本的秩次差； a 为样本组数。

在含重复值时，斯皮尔曼相关系数 ρ 的通用计算公式如式(2)所示。

$$\rho = \frac{\text{cov}(\mathbf{R}_X, \mathbf{R}_Y)}{\sigma_{R_X} \sigma_{R_Y}} \quad (2)$$

式中： \mathbf{R}_X 和 \mathbf{R}_Y 分别为原始数据向量 \mathbf{X} 和 \mathbf{Y} 的秩次向量； cov 为协方差； σ_{R_X} 和 σ_{R_Y} 分别为 \mathbf{R}_X 和 \mathbf{R}_Y

的标准差。

本文基于斯皮尔曼相关系数在预测前对天气数据进行特征筛选，寻找可能存在的无用数据和干扰数据，即与风电场输出功率相关性几乎为 0 的特征，避免其对实验过程产生影响，确保实验的简洁性与可靠性。此外，若计算设备的性能不足或计算时间不足，也可以根据计算结果删去部分相关系数较低的特征。

1.3 初步预测模型

PatchTST 是一种处理时间序列数据的 Transformer 架构变体。Patching 操作将时间序列分割为固定长度的部分，减少输入标记数量，降低模型的时间和空间复杂度，同时保持通道独立性，有效提取局部特征^[26]。独立通道设计通过将多变量时间序列视作独立频道，避免不同变量信息混杂，使模型能更专注于各变量的特征，提升泛化能力^[27]。模型将时间索引从 1 开始的长度为 L 的第 i 个一元序列记作 $\mathbf{x}_{i:L}^{(i)} = (x_1^{(i)}, \dots, x_L^{(i)})$, $i = 1, 2, \dots, M$ 。输入 $(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_L)$ 被拆分为 M 个一元序列 $\mathbf{x}^{(i)} \in \mathbb{R}^{1 \times L}$ ，每个序列分别被独立送入 Transformer 主干；然后，Transformer 主干相应地提供预测结果 $\hat{\mathbf{x}}^{(i)} = (\hat{x}_{L+1}^{(i)}, \dots, \hat{x}_{L+T}^{(i)}) \in \mathbb{R}^{1 \times T}$ ，其中 T 为时间长度^[26]；最后，通过将 M 个预测结果序列合并，得到最终预测结果。

在 Transformer 骨干部分，以 M 个一元序列中

的一个序列为例, 其为一个多变量时间序列数据集, 将长度为 L 的序列 $(\mathbf{x}_1, \dots, \mathbf{x}_L)$ 输入模型, 数据处理层接收到数据后将序列划分为 N 个 patch。 N 的计算公式如式(3)所示。

$$N = \frac{L - P}{S} + 2 \quad (3)$$

式中: L 为输入序列的长度; P 为 patch 长度; S 为步长。

Transformer 层将 patch 通过与 $\mathbf{W}_{\text{proj}} \in \mathbb{R}^{D \times P}$ 相乘映射到维度为 D 的空间, 得到特征投影, 并与位置编码 $\mathbf{W}_{\text{pos}} \in \mathbb{R}^{D \times N}$ 相加得到包含 patch 的时间顺序的序列 $\mathbf{x}_d^{(i)}$, 计算过程如式(4)所示。

$$\mathbf{x}_d^{(i)} = \mathbf{W}_{\text{proj}} \mathbf{x}_{\text{pat}}^{(i)} + \mathbf{W}_{\text{pos}} \quad (4)$$

式中: \mathbf{W}_{proj} 为映射矩阵; $\mathbf{x}_{\text{pat}}^{(i)}$ 为第 i 个 patch; \mathbf{W}_{pos} 为位置编码矩阵; d 为维度索引。

使用多头注意力中的每个头部 h 将 $\mathbf{x}_d^{(i)}$ 转换为 Query 向量 \mathbf{Q} 、Key 向量 \mathbf{K} 和 Value 向量 \mathbf{V} , 计算如式(5)一式(7)所示。

$$\mathbf{Q}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^Q \quad (5)$$

$$\mathbf{K}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^K \quad (6)$$

$$\mathbf{V}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^V \quad (7)$$

式中: $\mathbf{Q}_h^{(i)}$ 为第 i 个输入在第 h 个注意力头上的 Query 向量; $\mathbf{K}_h^{(i)}$ 为第 i 个输入在第 h 个注意力头上的 Key 向量; $\mathbf{V}_h^{(i)}$ 为第 i 个输入在第 h 个注意力头上的 Value 向量; \mathbf{W}_h^Q 为第 h 个 \mathbf{Q} 变换矩阵; \mathbf{W}_h^K 为第 h 个 \mathbf{K} 变换矩阵; \mathbf{W}_h^V 为第 h 个 \mathbf{V} 变换矩阵^[27]。

将注意力得分进行 Softmax 归一化, 得到权重矩阵, 矩阵的每个值都大于 0 且小于 1, 且总和为 1。将权重矩阵与 \mathbf{V} 相乘, 加权求和得到输出结果 $\mathbf{O}_h^{(i)}$ 。计算公式如式(8)所示。

$$(\mathbf{O}_h^{(i)})^T = \text{Softmax} \left(\frac{\mathbf{Q}_h^{(i)} (\mathbf{K}_h^{(i)})^T}{\sqrt{d_k}} \right) \mathbf{V}_h^{(i)} \quad (8)$$

式中: d_k 为 Key 向量的维度。

最后将 $\mathbf{O}_h^{(i)}$ 展平后至由全连接层构成的预测头中, 得到最终预测结果^[26,28]。

超短期风电功率预测具有如下特征: 1) 风电场输出功率受风速、风向、温度、气压等众多因素影响, 多条件风电功率预测属于高维预测; 2) 风电场风速和风向等具有一定随机性, 导致发电功率波动性大。这种随机性是风电预测的一大挑战; 3) 风电场天气数据与风电功率之间的关系通常为非线性;

4) 超短期风电功率预测为多步预测, 模型输入、输出数据量大。根据上述分析, PatchTST 模型能够将长时间序列分割为局部块, 显著降低 Transformer 的输入长度, 缓解计算复杂度。这使模型能够高效利用历史数据捕捉季节性、天气突变等长距离依赖; 模型将每个天气特征(风速、风向、温度等)作为独立通道处理, 分块后通过共享权重编码, 既保留了变量特性, 又减少了参数量, 十分适合解决高维预测问题; 模型的分块操作对局部噪声具有平滑作用, 而注意力机制可抑制无关变量的干扰。因此, 本文选择 PatchTST 模型作为超短期风电功率初步预测模型。

1.4 误差修正模型

由于风电功率变化波动大, 变化趋势难以捕捉, 且超短期风电功率预测为多步预测。因此, PatchTST 模型的初步预测未能完全捕捉天气特征与功率之间的复杂关系, 使预测结果存在系统性误差。这类误差具有可预测性、短时波动性、长时趋势性、非线性等特点。由于误差是通过与天气特征高度相关的初步预测结果计算得到, 因此误差序列仍与天气特征具有高度相关性。故需要深度挖掘天气数据与误差数据之间的关系, 从而对风电功率初步预测结果进行有效修正。iTransformer 模型凭借其反转式结构设计, 能够有效捕捉初步预测模型未能捕捉到的变量间的复杂关系。因此, 本文在风电功率初步预测后加入了以天气特征为输入的误差修正模型 POA-VMD-iTransformer。通过将误差修正模型与 PatchTST 模型相结合, 有效解决了单一模型自身存在的局限性以及单一模型预测存在的系统性偏差。同时, 有效降低了部分时间极端天气数据对预测结果的影响。总体体现在混合预测模型相较于单一模型具有更小的预测误差和更优的泛化性。

1.4.1 鹈鹕优化算法

POA 是一种基于群体智能的元启发式优化算法。该算法模拟了鹈鹕的捕食行为和社会交互特性, 用于解决复杂的优化问题^[29-30]。其通过个体之间的协作与竞争, 寻找全局最优解, 适用于多种优化场景。其适应性强、收敛迅速, 在解决 VMD 调参这类高维非线性问题时表现出色。其在解决全局最优解问题中的表现要明显优于鲸鱼优化算法(whale optimization algorithm, WOA)、灰狼优化算法(grey wolf optimizer, GWO)、粒子群优化算法(particle swarm optimization, PSO)等方法^[29]。

POA 构建了探索策略与开发策略。探索策略中鹈鹕个体位置更新如式(9)所示。

$$x_{q,j}^{\text{pha1}} = \begin{cases} x_{q,j} + r \cdot (p_j - I \cdot x_{q,j}), & F_{\text{prey}} < F_q \\ x_{q,j} + r \cdot (x_{q,j} - p_j), & \text{else} \end{cases} \quad (9)$$

式中： $x_{q,j}^{\text{pha1}}$ 为第 q 个鹈鹕探索阶段结束后在第 j 维的位置； $x_{q,j}$ 为第 q 个鹈鹕在第 j 维的位置； p_j 为猎物在第 j 维的位置； F_{prey} 为猎物的目标函数值； F_q 为第 q 个鹈鹕的目标函数值； r 为区间[0,1]中的随机数； I 为步长因子，随机等于 1 或 2，每次迭代都会更新。 I 影响 POA 的空间搜索能力，当 $I=2$ 时，鹈鹕个体以更大的位移搜索空间。

开发策略中鹈鹕个体位置更新如式(10)所示。

$$x_{q,j}^{\text{pha2}} = x_{q,j} + G \cdot \left(1 - \frac{c}{C}\right) \cdot (2 \cdot r - 1) \cdot x_{q,j} \quad (10)$$

式中： $x_{q,j}^{\text{pha2}}$ 为第 q 个鹈鹕个体开发阶段结束后在第 j 维的位置； $G \cdot \left(1 - \frac{c}{C}\right)$ 为 $x_{q,j}$ 的邻域半径，其中 G 为一个等于 0.2 的常数； c 为 POA 算法的迭代次数； C 为最大迭代次数^[29,31]。

本文使用 POA 对 VMD 算法的带宽约束参数和模态数量两个参数进行寻优，提升算法的泛化性和鲁棒性。本文选择 VMD 分解后误差序列残差的方差作为适应度函数。在 POA 优化前，残差的方差为 183.5650。在 POA 优化后，残差的方差为 50.9053。

1.4.2 变模态分解

VMD 分解是一种有效的信号分解方法，因其良好的分解效果和强抗噪性，特别适合处理随机性大、变化幅度大、规律性不明显的序列^[32-33]。VMD 分解的核心优势在于将复杂时序信号拆解为多个 IMF，每个 IMF 捕获信号的基本模式，对应不同频谱成分。VMD 能够将复杂序列分解成若干个幅度和频率可调的信号，有效改善了经验模态分解(empirical mode decomposition, EMD)在分解过程中的模态混叠问题和集合经验模态分解(ensemble empirical mode decomposition, EEMD)特征频率不易区分的问题^[34]。与传统傅里叶变换相比，VMD 在处理非线性、非平稳序列时能够依据数据自身特性自适应地确定模态特征，因此其具有更高的适用性^[33]。

首先，对于输入信号，VMD 算法生成的约束变分问题表示为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^B \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^B u_k(t) = f(t) \end{cases} \quad (11)$$

式中： B 为模态函数个数； ω_k 为各模态中心频率；

$\{u_k\}$ 、 $\{\omega_k\}$ 分别为模态集合和中心频率集合； ∂_t 为对 t 求偏导； $\delta(t)$ 为单位脉冲函数； $u_k(t)$ 为第 k 个 IMF 分量； $f(t)$ 为原始序列；“*” 为卷积运算。

其次，引入二次惩罚项 α 和拉格朗日乘子 $\lambda(t)$ 将约束问题转换为无约束最优化问题，如式(12)所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^B \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^B u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^B u_k(t) \right\rangle \quad (12)$$

然后，通过交替方向乘子法更新 u_k 、 ω_k 、 λ ，计算如式(13)一式(15)所示。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{s \neq k} \hat{u}_s(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (13)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (14)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_{k=1}^B \hat{u}_k^{n+1}(\omega) \right) \quad (15)$$

式中： n 为 VMD 算法的迭代次数； τ 为更新参数； $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$ 、 $\hat{\lambda}^n(\omega)$ 分别为 $u_k^{n+1}(t)$ 、 $f(t)$ 、 $u_k(t)$ 、 $\lambda(t)$ 、 $\lambda^n(t)$ 的傅里叶变换。

最后，给定判别精度 ε ，且 $\varepsilon > 0$ ，满足式(16)。

$$\sum_{k=1}^B \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (16)$$

当满足式(16)时，即可得到分解子序列^[35-36]。

由于误差序列具有非平稳性和复杂性，直接对原始误差序列进行建模，往往难以有效捕捉其内在的复杂规律。而 VMD 分解能够有效区分低频趋势与高频噪声，为后续预测模型去除干扰因素，提升预测精度。因此，本文在误差序列预测前，先对误差序列进行 POA-VMD 分解，从中提取简单的子序列。然后针对每个净化后的 IMF 单独建模，通常比直接处理复杂原生信号更为简单有效。经过 POA-VMD 分解，iTransformer 模型可以更好地学习天气特征与误差序列之间的关系。最终通过整合各 IMF 的预测输出，重构得到全局预测结果。

1.4.3 iTransformer

iTransformer 是一种创新性的深度学习模型。其结构采用反转式设计，能够将各序列独立嵌入为变量标记，而非将多个变量嵌入为一个时间标记。这种设计使模型能够更好地捕捉时间序列的全局特

征。同时, 通过独立处理各变量, 注意力模块能够更有效地捕捉变量间的相关性, 优化了任意回溯窗口的利用率, 提升了模型的预测能力^[37-38]。此外, 该模型在多个模块中均进行了创新性设计与改进。其层归一化模块对每个变量单独作归一化处理, 减少了变量间的差异, 避免了传统方法可能引入的交

互噪声; 其前馈网络作用于整条序列, 能够有效提取序列的内在属性; 其注意力机制应用于变量维度而不是传统的时间维度, 提升了模型对变量间关系的学习能力。Transformer 与 iTransformer 模型的对比如图 2 所示。

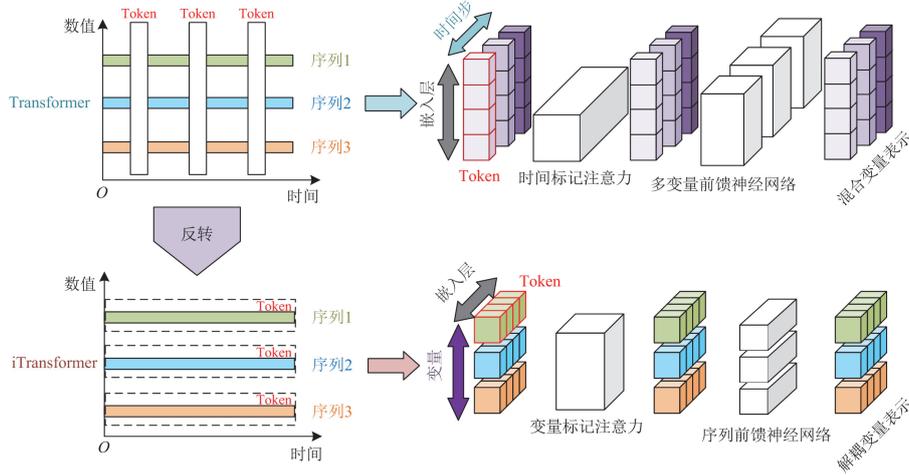


图 2 Transformer 与 iTransformer 模型对比

Fig. 2 Comparison between Transformer and iTransformer models

在 iTransformer 模型中, 基于历史观测序列 $X_{:,m}$ 预测每个变量的未来序列 $\hat{Y}_{:,m}$, 预测过程表达式如式(17)一(19)所示。

$$\mathbf{h}_m^0 = \text{Embedding}(X_{:,m}) \quad (17)$$

$$\mathbf{H}^{l+1} = \text{TrmBlock}(\mathbf{H}^l), l = 0, \dots, U-1 \quad (18)$$

$$\hat{\mathbf{Y}}_{:,m} = \text{Projection}(\mathbf{h}_m^U) \quad (19)$$

式中: \mathbf{h}_m^0 为第 m 个变量在输入层经过嵌入操作后得到的初始嵌入结果; $\mathbf{H} = \{\mathbf{h}_1, \dots, \mathbf{h}_Z\} \in \mathbb{R}^{Z \times D}$, Z 为变量个数, D 为特征维度; $\mathbf{h}_v \in \mathbb{R}^D$, $v = 1, \dots, Z$ 为单一变量在过去时间内的时序变化, 称为变量 Token; m 为变量索引; U 为编码器层数; \mathbf{h}_m^U 为第 U 层编码器输出的第 m 个变量的隐藏状态向量; Embedding 为嵌入操作; TrmBlock 为各层编码器; Projection 为投影操作^[38]。

本文综合使用 POA、VMD 和 iTransformer 对超短期风电功率初步预测结果进行误差修正。

1) 基于训练集(含验证集)训练误差修正模型。首先, 将 PatchTST 模型训练集的功率预测结果与真实值相减, 得到误差序列。然后, 误差序列经过 POA-VMD 分解后, 将各 IMF 作为真值, 与风电场天气特征一起输入 iTransformer 模型进行训练。

2) 基于测试集完成误差修正。首先, 由于

iTransformer 模型在训练阶段已经学习到误差的规律, 在测试阶段, iTransformer 模型根据训练集误差序列的各 IMF, 并结合相应天气数据逐段预测各 IMF 在测试集对应时间步上的值, 将这些预测值合并作为测试集的误差修正结果。然后, 将风电功率初步预测结果与误差修正结果对应时间步相加, 作为最终的风电功率预测结果, 完成误差修正。

2 实例验证与结果分析

本文使用中国新疆某风电场 2019 年全年数据对模型进行验证。本实验基于 13th Gen Intel(R) Core(TM) i9-13900K CPU@3.00 GHz, 128 G RAM, 1 块 NVIDIA GeForce RTX 4090 GPU, Python 3.7, pytorch 1.12.1, cuda11.6 服务器进行实验。

2.1 实验数据

本文使用的中国新疆某风电场 2019 年全年数据的天气特征包括: 测风塔 10 m 风速(m/s)、测风塔 30 m 风速(m/s)、测风塔 50 m 风速(m/s)、测风塔 10 m 风向($^\circ$)、测风塔 30 m 风向($^\circ$)、测风塔 50 m 风向($^\circ$)、温度、气压(hPa)和湿度(%)。根据这些特征来预测风电场发电功率。数据中每条数据的时间间隔为 15 min。设置预测步长为 16 步, 每一步为 15 min, 故每次预测的时间为 4 h。设置训练集、验证集、测试集之比为 7:1:2。

2.2 数据筛选

本文使用斯皮尔曼相关系数法进行天气特征与风电功率相关性量化分析, 计算得到的相关系数热力图如图 3 所示。由于本实验的数据中各天气特征与风电功率的相关系数不存在极低值, 且拥有充足的计算资源。因此, 将使用所有 9 个天气特征对风电功率进行预测。

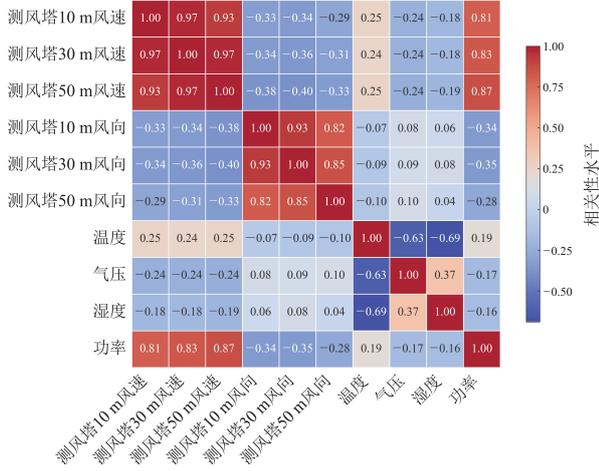


图 3 相关性分析热力图

Fig. 3 Heatmap of correlation analysis

2.3 评价指标

本文使用均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数 R^2 来评价各模型预测风电功率的性能。RMSE、MAE 的值越小, 代表模型的预测精度越高。 R^2 的值越接近 1, 代表模型越能够较好地拟合数据的变化趋势。RMSE、MAE 和 R^2 的计算方法分别如式(20)一式(22)所示。

$$E_{RMSE} = \sqrt{\frac{\sum_{r=1}^z (y_r - \tilde{y}_r)^2}{z}} \quad (20)$$

$$E_{MAE} = \frac{\sum_{r=1}^z |y_r - \tilde{y}_r|}{z} \quad (21)$$

$$R^2 = 1 - \frac{\sum_{r=1}^z (y_r - \tilde{y}_r)^2}{\sum_{r=1}^z \left(y_r - \frac{\sum_{r=1}^z y_r}{z} \right)^2} \quad (22)$$

式中: E_{RMSE} 为均方根误差; E_{MAE} 为平均绝对误差; R^2 为决定系数; y_r 为真实值; \tilde{y}_r 为预测值; z 为样

本数量。

2.4 超短期风电功率预测实验

本文使用 PatchTST 模型对风电场输出功率进行初步预测。PatchTST 模型的超参数设置如表 1 所示。

表 1 PatchTST 超参数设置

Table 1 PatchTST hyperparameter settings

参数	取值
批次	32
编码器层数	2
注意力头数	8
模型尺寸	512
预测步长	16
学习率	自适应调节
优化器	Adam

本文使用 POA 优化的 VMD 算法对训练集的预测误差序列进行分解。误差序列 POA-VMD 分解后各 IMF 序列曲线如图 4 所示。随后, 使用 POA-VMD-iTransformer 模型对初步预测结果进行误差修正, 得到超短期风电功率最终预测结果。由实验结果可得, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 为 16.9944、MAE 为 10.8928、 R^2 为 0.8949。从实验结果可以看出, 本文模型具有足够低的预测误差和足够高的预测精度, 可以有效应对风电随机性和波动性等问题, 能够满足各风电场和电网对超短期风电功率预测的要求。

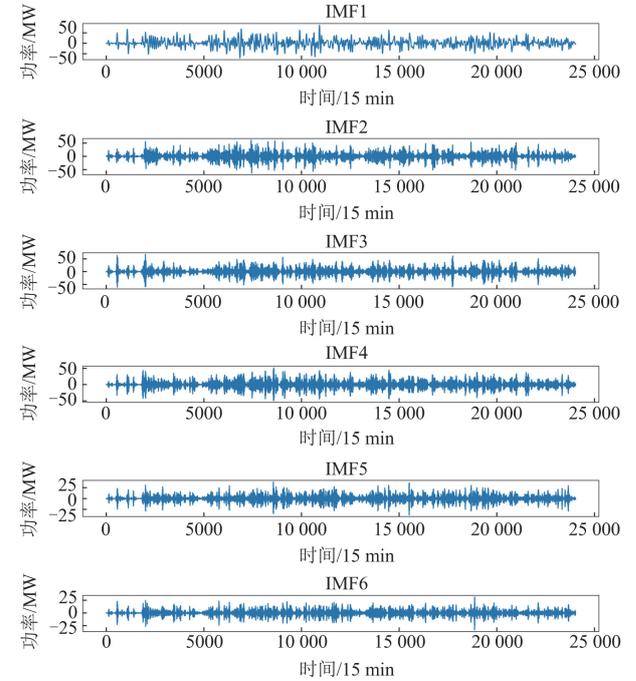


图 4 POA-VMD 分解后误差序列曲线

Fig. 4 Error sequence curves after POA-VMD

2.5 消融实验

2.5.1 风电功率预测模型消融实验

由于风力发电输出功率波动大、变化趋势难以准确捕捉, 尤其是在预测步长为 16 的情况下, 使用单一预测模型往往会产生较大的预测误差。因此, 本文引入误差修正方法, 对 PatchTST 预测的风电功率结果进行修正。研究通过消融实验探究了风电功率预测模型中是否引入误差修正的影响, 以评估其有效性和必要性。消融实验结果如表 2 和图 5 所示。

表 2 各模型风电功率预测结果对比

Table 2 Comparison of wind power forecasting results for various models

模型	RMSE	MAE	R^2
RNN	43.7120	31.2589	0.3046
LSTM	43.0536	31.3912	0.3254
BiGRU	42.6759	30.0401	0.3371
Transformer	39.5023	28.1667	0.4321
Informer	33.5959	20.1632	0.5892
FEDformer	31.7855	21.3903	0.6323
DLinear	30.7837	21.3828	0.6551
iTransformer	31.3949	18.5959	0.6413
PatchTST	29.6081	17.1216	0.6809
PatchTST-DLinear	26.8185	16.4842	0.7382
PatchTST-PatchTST	27.1862	16.4521	0.7310
PatchTST-iTransformer	26.2365	15.6731	0.7495
PatchTST-POA-VMD-DLinear	19.4324	11.7015	0.8626
PatchTST-POA-VMD-PatchTST	19.3324	12.5849	0.8640
PatchTST-POA-VMD-iTransformer	16.9944	10.8928	0.8949

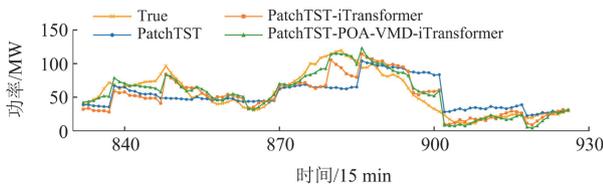


图 5 风电功率预测消融实验结果

Fig. 5 Ablation experiment results for wind power forecasting

加入 iTransformer 误差修正后, 相较于 PatchTST, PatchTST-iTransformer 模型预测结果的 RMSE 降低了 11.387%、MAE 降低了 8.460%、 R^2 提升了 10.075%; 加入 POA-VMD-iTransformer 误差修正后, 相较于 PatchTST, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 42.602%、MAE 降低了 36.380%、 R^2 提升了 31.429%。实验表明, 误差修正后的模型相比于单一模型具有更好的预测效果, 尤其是在功率数据变化剧烈的阶段, 加入误差修正的预测模型优势更加明显。由理论分析和实验结果可得, 误差修正模型 iTransformer 和

POA-VMD-iTransformer 能够充分利用其模型的结构优势, 学习误差序列与天气特征数据间的关系, 有效修正初步预测产生的误差。准确的误差序列预测结果也保证了其能够有效降低混合模型最终的预测误差。误差修正模型针对 PatchTST 预测中存在的误差, 对初步预测结果进行调整, 利用不同模型的特点对 PatchTST 的不足进行弥补和优化。因此, 误差修正不仅能够有效增强模型对时间序列数据变化趋势的学习能力, 还能够提升模型的泛化性和鲁棒性。

2.5.2 误差修正模型消融实验

由于误差序列表现出非平稳性和复杂性, 因此在对误差序列进行预测前, 有必要先对其进行 POA-VMD 分解。分解后各 IMF 的变化起伏低, 变化趋势更为明显, 有利于后续预测模型对误差序列的预测。本节将对误差修正前是否对误差序列 POA-VMD 分解进行消融实验, 验证 POA-VMD 分解对误差修正的有效性和必要性。消融实验结果如表 2 和图 5 所示。

加入 POA-VMD 分解后, 相较于 PatchTST-iTransformer, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 35.226%、MAE 降低了 30.500%、 R^2 提升了 19.400%。实验结果表明, 加入 POA-VMD 后, 误差修正模型能够更准确地预测误差序列的变化趋势。由理论分析和实验结果可得, POA-VMD 分解能够有效降低误差序列的复杂性, 使误差修正模型能够更好地学习误差序列与各变量间的关系以及误差序列自身的变化规律。因此, 在误差修正模块对误差序列进行 POA-VMD 分解十分有效且必要。

2.6 对比实验

2.6.1 风电功率初步预测模型对比实验

由于超短期风电功率预测模型众多, 本节将进行对比实验, 将 PatchTST 与多种预测模型进行对比, 计算评价指标, 旨在验证 PatchTST 在超短期风电功率初步预测方面的优越性。对比实验结果如表 2 和图 6 所示。

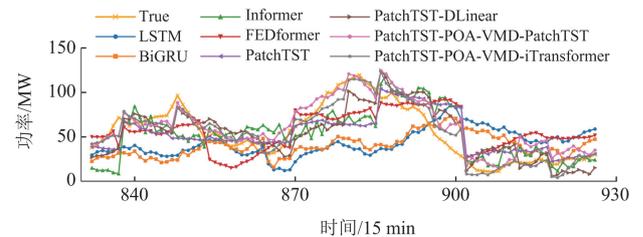


图 6 风电功率预测对比实验结果

Fig. 6 Comparative experiment results for wind power forecasting

与 DLinear、Informer、Transformer、BiGRU 等模型相比, PatchTST 的预测性能最佳。例如, 相较于 DLinear, PatchTST 模型预测结果的 RMSE 降低了 3.819%、MAE 降低了 19.928%、 R^2 提升了 3.938%。由理论分析和实验结果可得, PatchTST 模型通过将时间序列切分为局部块, 能够有效捕捉风电功率与天气特征的局部特征和长距离依赖关系, 同时降低计算复杂度。其独立通道设计能够有效提取天气因素的变量特征。因此, 本文选择 PatchTST 作为风电功率初步预测模型。

2.6.2 误差修正模型对比实验

本节将 PatchTST-POA-VMD-iTransformer 模型与多种含误差修正的预测模型进行对比, 计算评价指标, 旨在验证 POA-VMD-iTransformer 模型在误差序列预测方面的优越性。对比实验结果如表 2 和图 6 所示。

与含误差修正的预测模型相比, PatchTST-POA-VMD-iTransformer 模型的预测性能最佳。相较于 PatchTST-POA-VMD-DLinear, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 12.546%、MAE 降低了 6.911%、 R^2 提升了 3.744%; 相较于 PatchTST-POA-VMD-PatchTST, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 12.094%、MAE 降低了 13.445%、 R^2 提升了 3.576%。由理论分析和实验结果可得, 由于 iTransformer 的反向结构设计, 该模型能够有效地捕捉误差序列的全局特征, 同时可以对每个变量进行单独处理, 捕捉各变量之间的关系, 并有效减少了模型归一化处理时产生的噪声。基于这些特点, iTransformer 对误差序列这类波动大、规律难以捕捉、数据众多的多条件时间序列具有很好的多步预测效果。此外, 为避免由相同模型组成的混合模型会进一步放大该模型的缺点, 研究使用不同模型以实现各模型的优势互补。因此, 通过与多种模型对比分析, 本文选择 iTransformer 模型组成误差修正模块。

2.6.3 最终预测模型对比实验

本节将 PatchTST-POA-VMD-iTransformer 模型与多种预测模型进行对比, 计算其评价指标, 从而验证本文模型在超短期风电功率预测方面的优越性。对比实验结果如表 2 和图 6 所示。

与 PatchTST-POA-VMD-DLinear、FEDformer、Transformer、LSTM 等模型相比, PatchTST-POA-VMD-iTransformer 模型在超短期风电功率预测方面表现最佳。相较于 PatchTST-POA-VMD-DLinear, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 12.546%、MAE 降低了 6.911%、 R^2 提

升了 3.744%; 相较于 FEDformer, PatchTST-POA-VMD-iTransformer 模型预测结果的 RMSE 降低了 46.534%、MAE 降低了 49.076%、 R^2 提升了 41.531%。由理论分析和实验结果可得, 本文所提模型融合了 PatchTST、POA、VMD 与 iTransformer 方法的优势, 不仅能够精准学习风电功率的变化趋势, 而且在数据剧烈波动情境下表现出良好的适应性, 具备更优的预测精度、泛化能力与鲁棒性。

3 结论

本文首先基于斯皮尔曼相关系数对天气特征数据进行选择; 其次, 为提升超短期风电功率预测的精度和泛化性, 本文提出了一种 PatchTST-POA-VMD-iTransformer 混合模型。通过理论分析和实例验证得到以下结论。

1) PatchTST-POA-VMD-iTransformer 模型在超短期风电功率预测方面预测误差低, 预测精度高, 能够满足各风电场及电网对超短期风电功率预测准确性和稳定性的要求。

2) 消融实验进一步验证了 PatchTST-POA-VMD-iTransformer 在超短期风电预测方面的优势, 并揭示了 PatchTST-POA-VMD-iTransformer 结构中各部分的作用。加入 POA-VMD 分解能够提升误差序列预测精度; 加入 POA-VMD-iTransformer 误差修正能够提升风电功率预测精度。体现了 POA-VMD 和 iTransformer 在提高预测结果精度和泛化性方面的显著性和重要性。

3) 对比实验证明, 相较于其他模型, PatchTST 具有更好的风电功率初步预测结果, POA-VMD-iTransformer 具有更优的误差序列预测结果。将两者相结合组成的混合模型 PatchTST-POA-VMD-iTransformer 具有更高超短期风电功率预测精度。

结果表明, 本文提出的模型在捕捉风电功率动态变化方面具有优势, 并且其在众多预测模型中具有较优的预测效果, 为风电场、电网及电力市场提供了新颖且有效的超短期风电功率预测方法。本文的研究成果对人工智能深度学习领域的发展和应用也具有十分重要的意义和价值。

参考文献

- [1] 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 Yuhang, 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.

- [2] WU Zhou, LUO Gan, YANG Zhile, et al. A comprehensive review on deep learning approaches in wind forecasting applications[J]. *CAAI Transactions on Intelligence Technology*, 2022, 7(2): 129-143.
- [3] 张博宸, 周羽生, 周文晴, 等. 基于滑模观测器的三电平风力发电并网逆变器无差拍优化模型预测控制[J]. *电测与仪表*, 2024, 61(4): 176-183.
- ZHANG Bochen, ZHOU Yusheng, ZHOU Wenqing, et al. Optimal model predictive control for three-level grid-connected windpower inverters without differential beat based on sliding mode observer[J]. *Electrical Measurement & Instrumentation*, 2024, 61(4): 176-183.
- [4] 袁天梦, 宁亮, 巩彦江, 等. 考虑能量耗散的分布式风力发电并网电网容量扩充研究[J]. *电网与清洁能源*, 2024, 40(12): 135-140.
- YUAN Tianmeng, NING Liang, GONG Yanjiang, et al. Research on capacity expansion of distributed wind power grid-connected grids considering energy dissipation[J]. *Power System and Clean Energy*, 2024, 40(12): 135-140.
- [5] DHAKA P, SREEJETH M, TRIPATHI M M. A survey of artificial intelligence applications in wind energy forecasting[J]. *Archives of Computational Methods in Engineering*, 2024, 31(8): 4853-4878.
- [6] GU Bo, HU Hao, ZHAO Jian, et al. Short-term wind power forecasting and uncertainty analysis based on FCM-WOA-ELM-GMM[J]. *Energy Reports*, 2023, 9: 807-819.
- [7] KANAGARATHINAM K, ARUNA S K, RAVIVARMAN S, et al. Enhancing sustainable urban energy management through short-term wind power forecasting using LSTM neural network[J]. *Sustainability*, 2023, 15(18).
- [8] 史加荣, 赵丹梦, 王琳华, 等. 基于 RR-VMD-LSTM 的短期风电功率预测[J]. *电力系统保护与控制*, 2021, 49(21): 63-70.
- SHI Jiarong, ZHAO Danmeng, WANG Linhua, et al. Short-term wind power prediction based on RR-VMD-LSTM[J]. *Power System Protection and Control*, 2021, 49(21): 63-70.
- [9] TANG Zao, LIU Jia, NI Jielong, et al. Power prediction of wind farm considering the wake effect and its boundary layer compensation[J]. *Protection and Control of Modern Power Systems*, 2024, 9(6): 19-29.
- [10] 陈瑶, 陈晓宁. 基于自适应 Kmeans 和 LSTM 的短期光伏发电预测[J]. *电测与仪表*, 2023, 60(7): 94-99.
- CHEN Yao, CHEN Xiaoning. Prediction of short-term photovoltaic power generation based on adaptive Kmeans and LSTM[J]. *Electrical Measurement & Instrumentation*, 2023, 60(7): 94-99.
- [11] 刘新宇, 蒲欣雨, 李继方, 等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. *电力系统保护与控制*, 2023, 51(21): 158-165.
- LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. *Power System Protection and Control*, 2023, 51(21): 158-165.
- [12] GAO Jian, YE Xi, LEI Xia, et al. A multichannel-based CNN and GRU method for short-term wind power prediction[J]. *Electronics*, 2023, 12(21).
- [13] 石立国, 李延真, 刘继彦, 等. 电动汽车充电站超短期充电负荷预测的改进 GRU 方法[J]. *供用电*, 2023, 40(6): 42-47.
- SHI Liguang, LI Yanzhen, LIU Jiyan, et al. Improved GRU method for ultra-short-term charging load forecasting at electric vehicle charging stations[J]. *Distribution & Utilization*, 2023, 40(6): 42-47.
- [14] QU Kai, SI Guangquan, SHAN Zihan, et al. Short-term forecasting for multiple wind farms based on transformer model[J]. *Energy Reports*, 2022, 8: 483-490.
- [15] HUAN Jiafei, DENG Li, ZHU Yue, et al. Short-to-medium-term wind power forecasting through enhanced transformer and improved EMD integration[J]. *Energies*, 2024, 17(10).
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998-6008.
- [17] WANG Jianzhou, QIAN Yuansheng, ZHANG Linyue, et al. A novel wind power forecasting system integrating time series refining, nonlinear multi-objective optimized deep learning and linear error correction[J]. *Energy Conversion and Management*, 2024, 299.
- [18] YE Lin, DAI Binhua, LI Zhuo, et al. An ensemble method for short-term wind power prediction considering error correction strategy[J]. *Applied Energy*, 2022, 322.
- [19] 李大中, 李颖宇. 基于深度学习与误差修正的超短期风电功率预测[J]. *太阳能学报*, 2021, 42(12): 200-205.
- LI Dazhong, LI Yingyu. Ultra-short term wind power prediction based on deep learning and error correction[J]. *Acta Energetica Solaris Sinica*, 2021, 42(12): 200-205.
- [20] YIN Shi, LIU Hui. Wind power prediction based on outlier correction, ensemble reinforcement learning, and residual correction[J]. *Energy*, 2022, 250.
- [21] 封钰, 宋佑斌, 金晟, 等. 基于随机森林算法和粗糙集理论的改进型深度学习短期负荷预测模型[J]. *发电技术*, 2023, 44(6): 889-895.
- FENG Yu, SONG Youbin, JIN Sheng, et al. Improved deep learning model for forecasting short-term load based on random forest algorithm and rough set theory[J].

- Power Generation Technology, 2023, 44(6): 889-895.
- [22] XIAO Zhengxuan, TANG Fei, WANG Mengyuan. Wind power short-term forecasting method based on LSTM and multiple error correction[J]. Sustainability, 2023, 15(4).
- [23] DONG Weichao, SUN Hexu, TAN Jianxin, et al. Short-term regional wind power forecasting for small datasets with input data correction, hybrid neural network, and error analysis[J]. Energy Reports, 2021, 7: 7675-7692.
- [24] ASLAM M, KIM J S, JUNG J. Multi-step ahead wind power forecasting based on dual-attention mechanism[J]. Energy Reports, 2023, 9: 239-251.
- [25] 甘恒玉, 黄莉, 刘兴举, 等. 基于 iInformer 的超短期风电功率多步预测[J]. 河南大学学报(自然科学版), 2024, 54(5): 576-586.
- GAN Hengyu, HUANG Li, LIU Xingju, et al. Multi-step prediction of ultra-short-term wind power based on iInformer[J]. Journal of Henan University (Natural Science), 2024, 54(5): 576-586.
- [26] NIE Y, NGUYEN N H, SINTHONG P, et al. A time series is worth 64 words: Long-term forecasting with transformers[J]. arXiv preprint arXiv: 2211. 14730, 2022.
- [27] HUANG Xinyu, TANG Jun, SHEN Yongming. Long time series of ocean wave prediction based on PatchTST model[J]. Ocean Engineering, 2024, 301.
- [28] 杨信廷, 郭向阳, 韩佳伟, 等. 基于 TiDE-PatchTST 模型的柑橘冷藏效率时序预测模型优化[J]. 农业机械学报, 2024, 55(7): 396-404.
- YANG Xinting, GUO Xiangyang, HAN Jiawei, et al. Optimization of citrus cold storage efficiency time-series prediction model based on TiDE-PatchTST[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 396-404.
- [29] TROJOVSKÝ P, DEGHANI M. Pelican optimization algorithm: a novel nature-inspired algorithm for engineering applications[J]. Sensors, 2022, 22(3).
- [30] JABARI M, EKINCI S, IZCI D, et al. Efficient DC motor speed control using a novel multi-stage FOPD(1+PI) controller optimized by the Pelican optimization algorithm[J]. Scientific Reports, 2024, 14(1).
- [31] 高玉超, 王占刚. 基于改进鹈鹕优化算法的土壤污染预测[J]. 计算机工程与设计, 2024, 45(9): 2852-2858.
- GAO Yuchao, WANG Zhangang. Prediction of soil pollution based on improved pelican optimization algorithm[J]. Computer Engineering and Design, 2024, 45(9): 2852-2858.
- [32] ZHANG Yagang, LI Ruixuan. Short term wind energy prediction model based on data decomposition and optimized LSSVM[J]. Sustainable Energy Technologies and Assessments, 2022, 52.
- [33] ZHANG Yagang, PAN Guifang, CHEN Bing, et al. Short-term wind speed prediction model based on GA-ANN improved by VMD[J]. Renewable Energy, 2020, 156: 1373-1388.
- [34] GAO Xiaozhi, GUO Wang, MEI Chunxiao, et al. Short-term wind power forecasting based on SSA-VMD-LSTM[J]. Energy Reports, 2023, 9: 335-344.
- [35] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [36] 陈春, 曹伯仲, 曹一家, 等. 高比例分布式电源接入下基于变分模态分解的励磁涌流辨识[J]. 电力系统保护与控制, 2024, 52(20): 94-104.
- CHEN Chun, CAO Bozhong, CAO Yijia, et al. Identification of inrush current based on variational model decomposition under a high proportion of distributed generation[J]. Power System Protection and Control, 2024, 52(20): 94-104.
- [37] HUANG Zhewei, YI Yawen. Short-term load forecasting for regional smart energy systems based on two-stage feature extraction and hybrid inverted transformer[J]. Sustainability, 2024, 16(17).
- [38] LIU Yong, HU Tengge, ZHANG Haoran, et al. itransformer: inverted transformers are effective for time series forecasting[J]. arXiv preprint arXiv: 2310. 06625, 2023.

收稿日期: 2024-11-21; 修回日期: 2025-04-07

作者简介:

刘新宇(1976—), 男, 博士, 教授, 研究方向为复杂建模及智能控制、新能源发电与智能电网; E-mail: lxy@ncwu.edu.cn

潘宇(2001—), 男, 硕士研究生, 研究方向为新能源发电、风电功率预测; E-mail: snowpy10@163.com

王亚辉(1987—), 男, 通信作者, 博士, 讲师, 研究方向为时序预测、水风光储多能系统优化调度。E-mail: wangyahuidl@ncwu.edu.cn

(编辑 许威)