

基于VMD-LSTM-MultiConv-SelfAttention的 超短期风电功率预测研究

任浩琴¹, 连维畅², 仝凤梧³, 王立敏¹, 赵树涵¹, 刘广臣¹

(1. 鲁东大学数学与统计科学学院, 烟台 264025; 2. 鲁东大学信息与电气工程学院, 烟台 264025;

3. 鲁东大学水利土木学院, 烟台 264025)

摘 要: 为提高风电功率预测精度同时确保电力系统的高效调度, 提出一种多算法集成的超短期风电功率预测模型, 通过变分模态分解(VMD)对功率序列进行噪声抑制与重构。在模型构建阶段, 利用LSTM捕捉时序依赖, 其后连接多层卷积神经网络提取局部特征并引入自注意力机制动态聚焦关键时间步, 形成多模块协同的预测框架。为检验模型的实效, 以山东省某风电场为核心开展消融、对比及季节迁移实验。结果显示: 相较于基准模型, 该模型的平均绝对误差MAE降低23.5%, 均方根误差RMSE减少20%, 可凸显各模块在捕捉复杂时序特征中的优势。进一步验证表明, 模型在跨区域(中西部风电场)与跨能源(光伏电站)场景中均表现优异, 凸显其强泛化能力。

关键词: 卷积神经网络; 自注意力机制; 风电功率; 梯度提升回归算法; 变分模态分解; 风电

中图分类号: TM614

文献标志码: A

0 引 言

随着全球能源转型, 风能在电力生产中的占比逐渐增加。鉴于风能的不稳定性, 提高风电功率预测的准确性成为当前电网的重要任务, 其对风电企业的规划管理、能源部门的稳定供电以及电力市场的高效运营具有深远影响。国内风电功率预测研究发展迅速, 涵盖了预测方法、模型优化以及数据处理技术等多方面, 研究时间尺度从超短期延伸到长期。刘德澳等^[1]提出的图神经网络方法能反映尾流作用, 但大规模数据计算复杂; 荆志宇等^[2]提出结合贝叶斯优化和通道注意力的双端优化时序式风电功率预测模型, 对数据质量和计算资源要求较高; 唐清苇等^[3]基于CNN-LSTM的迁移预测方法, 综合了多维特征; 据垚等^[4]提出改进乌鸦算法优化神经网络权重的短期组合预测法; 李润金等^[5]提出基于长短期记忆网络(long short-term memory, LSTM)的预测模型, 其精度高、适用性好, 但长时预测和泛化能力有待优化; 薛阳等^[6]提出一种结合卷积神经网络和门控循环单元的超短期风电功率预测方法; 郭凯杰等^[7]提出一种计及超短期预测误差的风储系统跟踪计划出力的控制策略; 李宏扬等^[8]针对光伏发电系统预测精度不高问题建立了以门控循环单元(gated recurrent unit, GRU)为基础的预测模型; 王献志等^[9]提出一种考虑时间序列和多特征的光伏发电功率XGBoost联合预

测模型; 胡云峰^[10]构建并使用风电功率预测模型, 但未考虑风速突变。LSTM在时间序列的分类和预测中有一定优势, 其基本原理可参考文献[11-13]。

国外相关研究也在积极推进, 研究包括预测方法、机器学习集成算法和数据分析处理技术, 涉及的时间尺度广泛。传统的预测方法, 如时间序列分析和机器学习, 在捕捉复杂非线性关系、处理大规模数据以及精度等方面存在局限性。因此, 当前的研究重点更倾向于深度学习技术。文献[14]提出分层递归神经网络(layered recursive neural network, LRNN)预测模型; 文献[15]通过SSA和ICEEMDAN降噪, 通过多方法组合实现风速预测及分析; 文献[16]提出通过分解、多模型组合预测风速及误差的方法; Blfceh等^[17]采用BNN-RNN并扩展贝叶斯网络, 用互熵法降维整合多数据输入进行风能预测; Khodayar等^[18]推出网格化算法, 但强烈依赖参数化方法, 稳定高质量的实现较为困难; Tacjana等^[19]利用多种类型深度神经网络解决短期风电功率预测问题, 其优势是使用极小的参数子集进行高效预测。

在国内外风电功率预测研究中, 传统物理和统计模型、机器学习方法以及混合模型均有所涉及。传统方法的预测精度相对较低且高度依赖大量气象数据。机器学习方法在处理大规模和多维时空数据方面的能力有限。目前该领域仍面临大规模数据处理、模型泛化能力不足、计算复杂度高

收稿日期: 2025-01-24

基金项目: 山东省重点研发计划(2024LZGCQY012); 国家级大学生创新创业训练项目(202410451008)

通信作者: 刘广臣(1978—), 男, 博士、副教授、硕士生导师, 主要从事机器学习算法及应用方面的研究。liuguangchen@ldu.edu.cn

和模型解释性差等问题。为此,本文提出一种多卷积结合自注意力机制的 LSTM 模型,通过卷积核提取特征,结合自注意力机制融合信息,获取更准确丰富特征表示,改进现有不足,以期提高超短期风电功率预测的精度和模型可解释性。

1 模型原理

1.1 变分模态分解

变分模态分解 (variational mode decomposition, VMD) 通过优化各模态分量的带宽估计解决约束变分问题,最终得到最优解,其约束变分问题模型为:

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

式中: ∂_t ——对 t 的偏导算子; $\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t)$ —— $u_k(t)$ 的希尔伯特变换; $\delta(t)$ ——狄拉克函数; j ——虚数单位; $*$ ——卷积; ω_k ——各模态分量 $u_k(t)$ 的中心频率; $y(t)$ ——风电功率原始序列。

为求解约束变分的最优解,本文引入二次惩罚因子 α 及拉格朗日算子 $\lambda(t)$,将原本的约束问题转化为非约束问题,简化问题的求解步骤,确保约束条件的严格性。

首先,引入拉格朗日乘子 λ 和二次惩罚因子 α 进行求解:

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

式中: $\alpha > 0$; $\langle \cdot, \cdot \rangle$ ——函数内积算子。

采用交替方向乘子法 (ADMM) 来交替更新 $\{u_k\}, \{\omega_k\}$ 和 λ , $\hat{y}(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别表示 $y(t)$ 、 $u_k(t)$ 、 $\lambda(t)$ 的傅里叶变换,当 $\{u_k\}, \{\omega_k\}$ 和 $\lambda(t)$ 给定时,先更新 $u_k(t)$ 的傅里叶变换再更新中心频率 ω_k ,最后更新拉格朗日乘子 λ 的傅里叶变换,其公式为:

$$\hat{u}_k(\omega) = \frac{\hat{y}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k := \frac{\int_0^{+\infty} \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^{+\infty} |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

$$\hat{\lambda}(\omega) := \hat{\lambda}(\omega) + \tau \left(\hat{y}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) \right) \quad (5)$$

式中: τ ——步长, $\tau > 0$ 。

经多次迭代后如果满足停止条件则终止迭代,输出 $\{\hat{u}_k(\omega)\}_{k=1}^K$,若不满足则继续该迭代流程,最后针对上述迭代过程输出的 $\hat{u}_k(\omega)$,执行傅里叶反变换得到 $u_k(t)$ 。

1.2 一维卷积神经网络

卷积神经网络 (convolutional neural network, CNN), 卷积层和池化层是其关键组成部分,在处理多变量时间序列时,采用一维卷积,如图 1 所示。




图 1 一维卷积神经网络原理图

Fig. 1 Principle of 1D convolutional neural network

卷积层通过卷积操作对输入数据矩阵进行局部特征提取,卷积核翻转后与输入数据的局部区域进行点乘并累加,输出结果为特征图。具体操作可表示为:

$$O(x, y) = (I(x, y) * k(x, y)) \quad (6)$$

式中: $I(x, y)$ ——输入矩阵中位于 x 行 y 列的元素; $k(x, y)$ ——卷积核权重; $O(x, y)$ ——输出卷积结果。

卷积核提取的特征在经过激活函数 (rectified linear unit, ReLU) 处理后形成一系列特征序列:

$$M_i = f(I * K_i + b_i) \quad (7)$$

式中: f ——激活函数; K_i ——第 i 个卷积核; b_i ——对应偏置。

池化层通过选取局部区域内的最大值或平均值,压缩特征图并减少计算复杂度。池化操作:

$$O_{\text{pool}}(x, y) = \text{pool}(I(x, y)) \quad (8)$$

式中: pool ——池化操作。

通过对卷积特征进行降采样,可实现特征选择和压缩。通过堆叠多个卷积层和池化层,逐步提取输入数据的多层次特征。

2 VMD-LSTM-MultiConv-SelfAttention 超短期风电功率预测模型

2.1 建模流程

为提高风电功率预测的效率和准确性,本文构建 VMD-LSTM-MultiConv-SelfAttention 超短期预测模型,基本原理如图 2 所示。




图2 预测模型流程图

Fig. 2 Flow of predictive model

具体步骤为:

1) 数据处理: 通过 K 最近邻算法 (K -nearest neighbors, KNN) 进行缺失插补。考虑到神经网络激活函数对输入数据在 $[-1, 1]$ 区间内的敏感性, 对数据进行归一化处理, 防止特征尺度差异对模型性能的影响。

2) VMD 分解与重构: 利用变分模态分解对原始风电功率信号寻优分解为 5 个固有模态 (intrinsic mode functions, IMF), 分解后将信号重构去除噪声, 为后续提供更加精确的输入。

3) 模型训练与预测: 将数据输入到 LSTM 中进行训练, 学习历史数据中的时序规律, 实验前, 数据预告被划分为训练集和测试集。使用均方误差 (mean squared error, MSE) 作为损失函数, 通过 AdamW 优化器进行优化, 以最小化训练过程中的预测误差。

为了提高模型的表现, 在 LSTM 层后全连接多层卷积模块, 进行卷积池化操作, 提取信号中的局部空间特征, 增强模型对细节波动的敏感性。此外, 为了让模型更加关注关键时间步的数据, 在拼接后引入自注意力机制。根据每个时间步的数据与其他时刻数据的关系来加权, 使模型能更关注对预测结果有重要影响的时刻, 并通过全连接层输出。在此过程中, 假设输入特征为 F , 首先通过线性变换公式分别转化为查询矩阵 Q 、键值矩阵 K 和数值矩阵 V , 变换公式为:

$$\begin{cases} Q = FW_Q \\ K = FW_K \\ V = FW_V \end{cases} \quad (9)$$

式中: W_Q 、 W_K 、 W_V ——可训练的权重矩阵。

通过计算 Q 与 K 的点积得到注意力得分, 通过 softmax 函数将得分转化为权重矩阵, 代表当前特征的重要程度, 计算公式为:

$$\text{Attention}(Q, K) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) \quad (10)$$

式中: d_k ——矩阵 Q 的维度, 用于缩放点积。

最后, 根据计算的注意力权重对所有值向量 V 进行加权求和, 得到新的特征向量 $\bar{F}$, 计算公式为:

$$\bar{F} = \text{Attention}(Q, K, V) = \text{Attention}(Q, K)V \quad (11)$$

自注意力机制可以更好地捕捉特征的长时序依赖关系, 如风速突变与后续功率波动的关系, 可进行动态权重分配, 对极端天气予以更高关注度, 如图 3 所示。




图3 自注意力机制原理图

Fig. 3 Diagram of the Self Attention mechanism

2.2 预测评价指标

采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、以及决定系数 (R-square, R^2) 作为预测准确性评估指标, 计算公式为:

$$e_{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (12)$$

$$e_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (13)$$

$$e_{MAPE} = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (15)$$

式中： y_i ——真实值； $\hat{y}_i$ ——预测值； $\bar{y}$ ——真实值的平均值； m ——样本数量。

3 算例分析

采用山东某风厂机组 2022 年 6 月 1—30 日间采集的包括风速、风向、叶片桨距角等共 15 维数据进行分析。原始数据的采样间隔为 15 min。将预处理后的数据按照 8:2 的比例划分进行训练测试。为有效捕捉风力机数据中的复杂模式并提取关键特征指标,采用梯度提升回归 (gradient boosting regression, GBR) 方法提取风速、叶片桨距角等 8 个特征。考虑到风电功率自身不平稳性和波动性可能引起的噪声问题,进一步采用变分模态分解 (VMD) 进行去噪,逐步优化提取 5 个 IMF 并对其进行重构,获得 VMD 处理后的风力发电功率序列分解结果,具体分解频率如图 4 所示。




图4 VMD实验结果

Fig. 4 Experimental results of VMD

3.1 模型性能对比消融实验

将所提模型与 VMD-LSTM-Multi-selfAttention、VMD-

LSTM、LSTM-MultiConv-SelfAttention 进行消融实验;与 VMD-BiLSTM-MultiConv-SelfAttention、EMD-LSTM-MultiConv-SelfAttention 进行对比实验,实验中相同模块配置一致,卷积核添加 1、3、5 的多尺度卷积层,提取不同尺度的特征。基于训练数据的 96 个时间步的历史数据进行风电功率超短期预测,并对 6 种模型的预测效果进行展示,结果如图 5 所示。结果表明,实验模型能有效跟踪实际风电功率的变化趋势。然而,在极值点的峰值和谷值处,预测结果普遍存在一定偏差,这可能与模型输入数据的特征质量及实际历史风电功率数据的惯性影响有关,导致模型在预测时出现轻微滞后性。相较于其他模型,VMD-LSTM-MultiConv-SelfAttention 模型在风电功率剧烈变化的极值点表现出更好的超短期预测精度,表明多尺度卷积与自注意力机制的结合提升了模型对复杂非线性风电功率变化的感知和预测能力,尤其在应对剧烈波动时,增强了模型的实际应用性能。




图5 真实值与预测值的比较

Fig. 5 Comparison of true value to predicted value

为了深入探讨 6 种模型在风电功率预测性能上的差异,引入 R^2 、MAE、RMSE、MAPE 这 4 种评价指标对模型的超短期预测性能进行评估,结果如表 1 所示。其中,基础模型 VMD-LSTM,未结合卷积网络和自注意力机制,在特征提取和捕捉长程依赖性方面表现相对有限,导致超短期预测精度不足。在此基础上,引入卷积神经网络构建 VMD-LSTM-MultiConv 模型,尽管卷积层的引入对特征提取能力有所增强,但模型仍未能更加有效地捕捉风电功率数据中的复杂模式,单纯依靠卷积结构在处理非线性和非平稳时序数据有一定的局限性。随后,增加自注意力机制,构建 VMD-LSTM-MultiConv-selfAttention 模型。同基础模型相比,模型的 MAE 降低了 23.5%,RMSE 减少了 20%,表明自注意力机制的引入显著提升了模型对复杂时间依赖关系的捕捉能力,更精准地识别短期波动模式。

表1 模型性能评价表

Table 1 Quantification of model performance evaluation indicators

模型	MAE	RMSE	MAPE/%	R^2
VMD-BiLSTM-MultiConv-SelfAttention	0.14	0.21	220.77	0.94
VMD-LSTM-Multi-SelfAttention	0.15	0.22	194.02	0.94
VMD-LSTM	0.17	0.25	284.99	0.92
EMD-LSTM-MultiConv-SelfAttention	0.23	0.35	319.84	0.86
LSTM-MultiConv-SelfAttention	0.21	0.32	187.82	0.89
VMD-LSTM-MultiConv-SelfAttention(本文方法)	0.13	0.20	167.89	0.95

此外,对比 VMD 和 EMD 的分解效果,VMD-LSTM-MultiConv-SelfAttention 的 RMSE 为 0.2013,EMD-LSTM-MultiConv-SelfAttention 的 RMSE 则高达 0.3475。结果表明,尽管 EMD 在处理某些非线性信号时具有优势,但其受限于端点效应,导致模态分离不够稳定,无法有效抑制噪声。而 VMD 通过优化迭代的方式,实现了更稳定的模态分离,从而有更加精确的超短期预测效果。随后探究 VMD-BiLSTM-MultiConv-SelfAttention 模型的效果,此模型结合双向 LSTM 结构,能更好地理解时间序列中的上下文信息,但整体仍未超越最优模型。值得注意的是,双向 LSTM 结构虽然提升了模型的上下文理解能力但增加了训练时间,在实际应用中可能影响模型的可部署性和实时性。

综上,实验结果验证了 VMD 分解、卷积神经网络和自注意力机制在提高风电功率超短期预测精度中的重要作用,各组件的结合改善了模型的整体性能和捕捉能力,可为处理复杂时序数据提供可靠的解决方案。

3.2 模型的不同季节适用性评价及归因分析

为验证模型对季节性气候变化的适应性,本研究基于山东某风电场数据开展跨季节迁移实验。选取典型月份(3、6、9、12 月份)的风电功率时序数据构建评估集,通过多维度指标对比分析模型的季节敏感性,结果如图 6、表 2 所示。

由表 2 可知,模型在冬季(12 月份)表现最优(RMSE、MAE 分别为 0.13、0.09),夏季(6 月份)误差相对较高(MAE、 R^2 分别为 0.13、0.95),春秋季节性能相对稳定($R^2 \geq 0.95$)。结







图6 同一台风力机在不同季节的风电功率数据
Fig. 6 Comparison of wind power data of same wind turbine in different seasons


表2 季节性能评价

Table 2 Seasonal performance evaluation


月份	R^2	MAE	RMSE
3	0.96	0.10	0.19
6	0.95	0.13	0.19
9	0.96	0.10	0.19
12	0.94	0.09	0.13

合山东温带季风气候特征,冬季盛行西北季风,夏季受东南季风与台风影响,这可能与不同季节的风速分布特性有关,其原因可能是:冬季风速较低且波动较为平缓(风速极差 16 m/s),功率序列呈现较为规律性波动变化(图 7),VMD 分解能有效分离低频主导模态,抑制随机噪声,同时 LSTM 对稳定时序的长期依赖捕捉能力较强,模型整体对线性趋势拟合更优,自注意力机制在多层卷积网络中对长期平稳序列的权重分配更均衡,减少了对突发波动的过拟合风险,故在冬季有更低的误差分布。夏季突发性阵风、切变风增多(图 7),功率序列出现高频非线性波动。VMD 分解后高频模态能量占比提升,但 LSTM 对短期突变的记忆能力有限,自注意力机制在快速变化时段可能出现权重分配滞后的问题,模型未能完全适应多因素耦合效应,导致结果稍差。春秋季气象条件温和,功率序列的噪声水平较低。VMD 分解后各模态能量分布均衡,自注意力机制动态聚焦关键时间步(清晨风速爬升段),MultiConv 通过不同卷积核捕获局部趋势与细节波动,二者协同提升了中频信号的预测精度,预测趋于稳定较高精度。


总体来说,模型全季 R^2 指标稳定保持于 94% 以上,MAE 波动范围控制在 0.09~0.13 之间,整体效果较好。其中,冬季预测效果更优源于气候稳定性与模型对低频信号的特化优



a. 夏季(6月份)



b. 秋季(9月份)



c. 冬季(12月份)

图7 风速变化比较

Fig. 7 Comparison of wind speed variations

势,而夏季误差略高则受限于高频突变与多因素耦合效应。未来可通过动态分解、物理约束建模与数据增强策略,进一步提升复杂气象条件下的预测鲁棒性。

3.3 跨区域数据集验证:模型泛化能力分析

为验证模型在不同气候与地理环境下的泛化能力,引入中国中西部地区某风电场 2019—2020 年间两年跨度数据(国家电网可再生能源预测竞赛数据集^[20]),时间粒度 15 min,包含轮毂高度风速、气温、湿度等 12 维特征。该区域属大陆性干旱气候,昼夜温差大,沙尘天气频发,风速突变频率更高,受复杂地形湍流影响更显著。采用与山东数据集一致的处理流程,模型性能对比如表 3 所示。由表 3 可知,相较于山东数据集,该模型在跨区域场景上 R^2 提升约 1.05%,RMSE 基本持平。中西部数据受沙尘干扰,VMD 通过自适应带宽优化,对噪声具有普适抑制能力。同时,中西部风速突变更频繁,MultiConv 模块通过 1×3 、 1×5 卷积核分别提取短期尖峰与中期趋势特征,证明其对局部波动模式的强泛化捕捉能力。原始数据集(山东)夏季样本中高速(>25 m/s)占比较低,模型对极端工况的学习不足。跨区域实验显示,在中西部地区夏季平均风速较低,模型 MAE 上升 3.2%(实际值由 0.1255 升至 0.1295),进一步印证了高频波动区域的泛化瓶颈。

表3 跨区域泛化性能对比

Table 3 Cross-regional generalization performance

数据集	MAE	RMSE	MAPE	R^2
中西部风电场(新增)	0.13	0.20	62.39	0.96
山东风电场(本文)	0.13	0.20	167.89	0.95

3.4 跨能源类型泛化验证

为验证模型对异构能源数据的泛化能力,新增中国信息通信研究院工业大数据产业创新平台提供的光伏发电数据集,包含 1 年脱敏运行数据(时间粒度 15 min),该数据集的光伏功率主要受辐照度、温度及组件物理特性影响,与风电的风速-桨距角动态关系截然不同,且受昼夜周期影响显著(夜间功率归零)。

表 4 跨能源类型性能对比

Table 4 Cross-energy type performance

数据集	MAE	RMSE	MAPE	R^2
光伏发电数据集(新增)	0.10	0.19	62.31	0.96
山东风电场(本文)	0.13	0.20	167.89	0.95

由表 4 可知,与风电数据集相比,模型在光伏场景下 MAE 降低 23.08%,MAPE 降低了 62.89%,表明其能有效适配不同能源的功率预测需求。光伏功率序列因昼夜周期呈现强周期性,VMD 分解自动识别主导低频模态,重构后保留辐照度-功率的物理关联性,噪声抑制效果与风电场景一致。同时,模型通过自注意力权重动态捕捉关键特征:白天高辐照度时段,注意力聚焦辐照度与组件温度交互项,补偿温度对光电效率的非线性衰减效应;阴雨天气,模型增强湿度与组件温度的关联计算,减少环境干扰导致的功率抖动。此项扩展验证了模型作为多能源功率预测通用框架的潜力,可为风光互补系统的协同预测提供技术基础。

4 结 论

本文提出一种基于 VMD-LSTM-MultiConv-SelfAttention 的超短期风电功率预测模型,通过构建 LSTM 捕捉时序依赖,多层卷积网络提取局部特征,并引入自注意力机制动态聚焦关键时间步,形成了端到端的预测框架,显著提升了预测精度与泛化能力。实验结果表明,该模型在山东某风电场的测试中,MAE 和 RMSE 相较基准模型分别降低 23.5% 和 20%, R^2 达到 0.95,验证了多模块协同在捕捉复杂时序特征方面的优势。在四季测试中,模型表现出较强的稳定性,其中冬季因气候条件平稳及低频特征占优,预测效果最佳;夏季受高频波动影响,误差略有上升,但仍优于对比模型。进一步在中西部风电场的数据集上,面对沙尘天气和风速剧烈变化等复杂场景,模型的 R^2 、MAE 仍保持在 0.96、0.13,显示出良好的跨区域适应性。此外,模型迁移应用于光伏功率预测时,MAE 较传统方法进一步下降了 23.08%,充分体现出其作为多能源通用预测框架的应用潜力。

当前模型在训练过程中计算复杂度较高,对硬件资源有较大依赖。此外,在高频突变及多因素强耦合条件下,模型性能仍存在一定波动。后续研究将考虑引入气象物理约束与数据增强策略,以提高模型在极端变化场景下的鲁棒性;同时,设计更加轻量化的网络结构以降低计算成本,并探索多模态融合方法,进一步增强模型在风光多能源系统联合预测中的应用能力。

[参考文献]

[1] 刘德澳,董明刚,叶威,等.基于图神经网络的非均匀风电场功率预测方法[J].太阳能学报,2023,44(11):

279-286.

LIU D A, DONG M G, YE W, et al. Power prediction method of non-uniform wind farm layout based on graph neural network[J]. Acta energiae solaris sinica, 2023, 44(11): 279-286.

[2] 荆志宇,李培强,林文婷.结合贝叶斯优化及通道注意力的双端优化时序式风电功率预测模型[J].电力系统及其自动化学报,2024,36(8):39-47,59.

JING Z Y, LI P Q, LIN W T. Double-side optimized time-series wind power prediction model combining Bayesian optimization and channel attention[J]. Proceedings of the CSU-EPSA, 2024, 36(8): 39-47, 59.

[3] 唐清苇,向月,代佳琨,等.基于CNN-LSTM的风电场发电功率迁移预测方法[J].工程科学与技术,2024,56(2):91-99.

TANG Q W, XIANG Y, DAI J K, et al. Wind farm power transfer forecasting method based on CNN-LSTM [J]. Advanced engineering sciences, 2024, 56(2): 91-99.

[4] 据垚,祁林,刘帅.基于改进乌鸦算法和ESN神经网络的短期风电功率预测[J].电力系统保护与控制,2019,47(4):58-64.

JU Y, QI L, LIU S. Short-term wind power forecasting based on improved crow search algorithm and ESN neural network [J]. Power system protection and control, 2019, 47(4): 58-64.

[5] 李润金,李丽霞.基于LSTM神经网络的风电功率预测研究[J].沈阳工程学院学报(自然科学版),2023,19(3):14-18.

LI R J, LI L X. Wind power prediction based on LSTM neural network [J]. Journal of Shenyang Institute of Engineering (natural science), 2023, 19(3): 14-18.

[6] 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 Y, WANG L, WANG S, 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.

[7] 郭凯杰,耿光超,江全元,等.计及超短期预测误差的风储系统跟踪计划出力控制策略[J].太阳能学报,2023,44(2):326-333.

GUO K J, GENG G C, JIANG Q Y, et al. Output control strategy of wind storage system tracking plan considering ultra short term prediction error[J]. Acta energiae solaris sinica, 2023, 44(2): 326-333.

[8] 李宏扬,高丙朋.基于改进VMD和SNS-Attention-GRU的短期光伏发电功率预测[J].太阳能学报,2023,44(8):292-300.

- LI H Y, GAO B P. Short-term PV power forecasting based on improved VMD and SNS-Attention-GRU [J]. *Acta energiae solaris sinica*, 2023, 44(8): 292-300.
- [9] 王献志, 曾四鸣, 周雪青, 等. 基于XGBoost联合模型的光伏发电功率预测[J]. *太阳能学报*, 2022, 43(4): 236-242.
- WANG X Z, ZENG S M, ZHOU X Q, et al. Power forecast of photovoltaic generation based on XGBoost combined model [J]. *Acta energiae solaris sinica*, 2022, 43(4): 236-242.
- [10] 胡云峰. 基于短期风电功率预测的桨距角优化研究[D]. 吉林: 东北电力大学, 2023, 1-64.
- HU Y F. Research on pitch angle optimization based on short-term wind power prediction [D]. Jilin: Northeast Electric Power University, 2023, 1-64.
- [11] 钱勇生, 邵洁, 季欣欣, 等. 基于LSTM-Attention网络的短期风电功率预测[J]. *电机与控制应用*, 2019, 46(9): 95-100.
- QIAN Y S, SHAO J, JI X X, et al. Short-term wind power forecasting based on LSTM-attention network [J]. *Electric machines & control application*, 2019, 46(9): 95-100.
- [12] 杨茂, 黄宾阳, 江博, 等. 基于卡尔曼滤波和支持向量机的风电功率实时预测研究[J]. *东北电力大学学报*, 2017, 37(2): 45-51.
- YANG M, HUANG B Y, JIANG B, et al. Real-time prediction for wind power based on Kalman filter and support vector machines [J]. *Journal of Northeast Dianli University*, 2017, 37(2): 45-51.
- [13] 黄万超. 机器学习技术在风力与光伏发电系统短期功率预测中的应用与比较研究[J]. *现代工业经济和信息化*, 2024, 14(10): 137-138.
- HUANG W C. Application and comparative study of machine learning techniques in short-term power prediction of wind and photovoltaic power generation systems [J]. *Modern industrial economy and informationization*, 2024, 14(10): 137-138.
- [14] ZHOU Y, RAVEY A, PERA M C. Real-time predictive energy management for fuel cell electric vehicles [C]//2021 IEEE Transportation Electrification Conference & Expo (ITEC). Chicago, IL, USA, 2021: 142-147.
- [15] SHANG Z H, CHEN Y H, LAI D K, et al. A novel interpretability machine learning model for wind speed forecasting based on feature and sub-model selection [J]. *Expert systems with applications*, 2024, 255: 124560.
- [16] XU H Y, CHANG Y Q, ZHAO Y, et al. A hybrid model for multi-step wind speed forecasting based on secondary decomposition, deep learning, and error correction algorithms [J]. *Journal of intelligent & fuzzy systems*, 2021, 41(2): 3443-3462.
- [17] BLFGEH A, ALKHUHDHAYR H. A machine learning-based sustainable energy management of wind farms using Bayesian recurrent neural network [J]. *Sustainability*, 2024, 16(19): 8426.
- [18] KHODAYAR M, KAYNAK O, KHODAYAR M E. Rough deep neural architecture for short-term wind speed forecasting [J]. *IEEE transactions on industrial informatics*, 2017, 13(6): 2770-2779.
- [19] NIKSA-RYNKIEWICZ T, STOMMA P, WITKOWSKA A, et al. An intelligent approach to short-term wind power prediction using deep neural networks [J]. *Journal of artificial intelligence and soft computing research*, 2023, 13(3): 197-210.
- [20] CHEN Y B, XU J J. Solar and wind power data from the Chinese State Grid Renewable Energy Generation Forecasting Competition [J]. *Scientific data*, 2022, 9: 577.

RESEARCH ON ULTRA SHORT TERM WIND POWER FORECASTING BASED ON VMD-LSTM-MULTICONV-SELFATTENTION

Ren Haoqin¹, Lian Weichang², Qi Fengwu³, Wang Limin¹, Zhao Shuhan¹, Liu Guangchen¹

(1. School of Mathematics and Statistics, Ludong University, Yantai 264025, China;

2. School of Information and Electrical Engineering, Ludong University, Yantai 264025, China;

3. School of Hydraulic and Civil Engineering, Ludong University, Yantai 264025, China)

Abstract: To enhance the accuracy of ultra-short-term wind power forecasting and support efficient power system dispatch, this study proposes an integrated multi-algorithm forecasting model. The variational mode decomposition (VMD) is firstly applied to suppress noise and reconstruct the original power sequence. In the modeling stage, a long short-term memory (LSTM) network is adopted to capture temporal dependencies, followed by a multi-layer convolutional neural network (CNN) to extract local features. A Self Attention mechanism is further incorporated to dynamically focus on critical time steps, resulting in a collaborative multi-module forecasting framework. To evaluate the performance of the proposed model, ablation studies, comparative experiments, and seasonal transfer tests were conducted using data from a wind farm in Shandong Province, China. The results show that, compared to baseline models, the proposed model reduces the mean absolute error (MAE) by 23.5% and the root mean square error (RMSE) by 20%, highlighting the advantages of each module in modeling complex temporal patterns. Additional validations in cross-regional (wind farms in Central and Western China) and cross-energy (photovoltaic plants) scenarios further demonstrate the model's strong generalization capability.

Keywords: convolutional neural network; Self-Attention mechanism; wind power prediction; gradient boosting regression algorithm; variational mode decomposition; wind power