

基于改进型变分模态分解和集成学习的超短期风功率预测

胡雅娇, 李培强

(福建理工大学 电子电气与物理学院, 福建 福州 350118)

摘要: 准确高效的风功率预测是保障电力系统安全经济运行的关键技术。然而, 风功率数据具有非线性、非平稳性的特征导致预测建模困难, 提出了一种基于改进型变分模态分解 (variational mode decomposition, VMD) 和 Stacking 集成学习的超短期风功率预测模型。首先, 通过 VMD 将历史风功率序列分解为相对简单的本征模态分量 (intrinsic mode function, IMF), 有效降低原始风功率序列的复杂度。其次, 利用由 C_0 复杂度和 Hurst 指数组成的分类复合指标将 IMF 分为简单趋势分量和复杂变化分量, 对简单趋势类分量采用长短期记忆网络 (long short-term memory, LSTM) 建模, 对复杂变化类分量采用带注意力机制的增强的 LSTM-Attention 作为基学习器进行预测。设计了基于卷积神经网络 (convolutional neural network, CNN) 的 Stacking 集成学习策略, 输入各个基学习器的预测值、未分解的原始风功率序列组作为元特征学习得到最终的预测结果。采用俄罗斯某风电场的实测数据构建超短期风功率预测场景, 实验结果表明, 结合改进型 VMD 能够实现更加精准的 IMF 分类, 采用 Stacking 集成学习组合各 IMF 分量预测值, 可以有效降低最终预测误差。与传统组合方法相比, 所提模型的预测精度提高了近 8%, 效率提高了近 40%。

关键词: 超短期风功率预测; 本征模态分量分类; 分类复合指标; 改进型变分模态分解; 集成学习

中图分类号: TM614

文献标志码: A

文章编号: 2097-3853(2025)06-0584-07

Ultra-short-term wind power prediction based on improved variational mode decomposition and ensemble learning

HU Yajiao, LI Peiqiang

(School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China)

Abstract: Accurate and efficient wind power prediction is a key technology for ensuring the safe and economic operation of the power system. However, the non-linear and non-stationary characteristics of wind power data make prediction modeling difficult. An ultra-short-term wind power prediction model based on improved variational mode decomposition (VMD) and Stacking ensemble learning was proposed. Firstly, the historical wind power sequence was decomposed into relatively simple intrinsic mode functions (IMF) through VMD, effectively reducing the complexity of the original wind power sequence. Secondly, the IMF was divided into simple trend components and complex change components using a classification composite index composed of C_0 complexity and Hurst exponent. The simple trend components were modeled using a long short-term memory (LSTM) network, while the complex change components were predicted using an enhanced LSTM Attention with attention mechanism as the base learner. A Stacking ensemble learning strategy based on convolutional neural network (CNN) was designed. The predicted values of each base learner and the original wind power sequence group without decomposition were input as meta features to learn the final prediction results. Using measured data from a wind farm in Russia to construct an ultra-short-term wind power prediction scenario, and experimental results show that combining the improved VMD can achieve more accurate IMF classification. Using Stacking ensemble learning to combine the predicted values of each IMF component can effectively reduce the final prediction error. Compared with traditional combination methods, the proposed model has improved prediction accuracy by nearly 8% and efficiency by nearly 40%.

Keywords: ultra-short-term wind power prediction; classification of intrinsic mode components; classification composite indicators; improved variational mode decomposition; ensemble learning

收稿日期: 2024-12-23

第一作者简介: 胡雅娇 (1997—), 女, 福建莆田人, 硕士研究生, 研究方向: 风功率预测。

通信作者: 李培强 (1975—), 男, 山西忻州人, 教授, 博士, 研究方向: 电力系统运行与控制及负荷建模。

在“双碳”战略目标驱动下,以风电为代表的新能源发电系统快速发展。然而,风电的强气象依赖性导致其出力波动大,引发风能消纳难、弃风率高及调度困难等问题,尤其在大规模风电并网后对电力系统安全稳定运行构成严峻挑战^[1]。准确高效的风电功率预测有助于提升风能利用率、降低调度难度并保障电力系统安全。

风功率预测方法可分为物理方法、传统统计方法和基于机器学习/深度学习的方法3类,其中基于机器学习/深度学习的方法因强大的特征提取能力成为主流^[2]。然而,风电数据复杂度高,直接建模难以充分挖掘其规律性。为此,“分解-预测”架构逐渐兴起。但现有方法对各IMF分量特征缺乏针对性,采用单一模型预测所有分量,既增加计算复杂度,又难以捕捉复杂分量的时序动态特性,从而最终影响预测性能^[3]。

基于上述问题,结合IMF分类指标的改进型信号分解技术在风功率组合预测中被推广应用。文献[4]和文献[5]分别采用游程检测法和样本熵将IMF分为高频、低频和余项3类。文献[6]认为基于样本熵改进的模糊熵也是IMF分类的指标之一。然而,上述研究均以单一指标为IMF分类的依据,没有综合考察各个IMF子序列的特征,难以实现准确的IMF分类,存在计算资源浪费、预测耗时长及预测精度不高等问题。此外,利用传统的叠加方法^[7]和加权方法^[8]在重构各个IMF预测值时易造成累积误差而影响最终预测结果,智能算法的引入虽在一定程度上改善了加权重构效果,仍存在较大误差,且其附带的计算负担过重等衍生问题也限制了其实际应用^[9]。文献[10]和文献[11]采用Stacking集成学习框架融合不同预测模型进行功率预测,取得较好的效果。

综上,本研究提出了一种基于改进型VMD和Stacking集成学习的超短期风功率预测方法,通过分解、分类和集成学习策略,实现高精度及高效率的超短期风功率预测。

1 风电数据分析

本研究采用俄罗斯某风电场为期一个月的历史风功率数据为分析样本,样本采集间隔为15 min,共有2 880个数据,如图1所示。




图1 俄罗斯某风电场风功率序列

Fig.1 Wind power sequence of a wind farm in Russia

1.1 非线性与非平稳性分析

为准确分析历史数据的时序特征,采用分形维数^[12]和增强型的迪基-富勒(augmented Dickey-fuller, ADF)检验^[13]作为量化指标。分形维数越大,非线性特征越显著;当ADF统计量的实际值比临界值(本研究选用-2.86)小,P值大于显著性水平(本研究选用0.05),表明序列为非平稳序列,比临界值小得越多、比显著水平大得越多,则非平稳性特征越强。经计算得,上述序列的分形维数为0.426 9;ADF统计量为-10.163 7,远小于临界值;P值为0.407 3,远大于显著水平,根据上述评价方法得,风功率序列具有显著非线性及非平稳性特征。

1.2 简单趋势分量与复杂变化分量

对历史风功率序列采用简单的移动平均滤波法进行分解,滤波处理前后的波形、分解所得的高低频分量分别如图2、图3所示。




图2 原始风功率序列与滤波后序列

Fig.2 Original wind power sequence and filtered sequence

由图2可得,滤波序列与原始序列趋势相近,但滤波序列更加平滑,即滤波后所得序列即为原始序列的低频分量,原始序列与低频分量之差为其高频分量,具体如图3所示。

为了对比数据分解前后序列的时序特征差异,同样利用上述的两种指标进行量化分析,其计算结果如表1所示。其中低频分量代表原始序列整体趋势且复杂度低,可归为简单趋势分量,适合采用简单的预测模型;高频分量复杂度高,适宜采用较为复杂的预测模型进行深度特征挖掘。




图 3 原始风功率序列的高低频分量

Fig.3 Low frequency and high-frequency components of original wind power sequence

表 1 高低频分量的分形维数及 ADF 检验结果

Tab.1 Fractal dimension and ADF test results of high and low frequency components

分量类型	分形维数	ADF 统计量	P
低频分量	0.198 8	-4.968 7	0.343 2
高频分量	0.764 9	-14.427 3	0.707 3

对比表 1 与 1.1 节的计算结果得,低频分量的非线性及非平稳性特征明显弱于原始序列,故采用信号分解技术有助于降低历史风功率序列的数据复杂度。

2 改进型 VMD 和 Stacking 集成学习的超短期风功率预测模型

基于改进型 VMD 和 Stacking 集成学习的超短期风功率预测方法采用了更高性能的信号分解技术,利用更为精准的指标对 IMF 进行分类,再为不同类型 IMF 建立合适的预测模型,以期进一步提升预测性能。

2.1 基于 IMF 分类复合指标的改进型 VMD

VMD 通过约束变分问题将信号分解为指定数量的 IMF 分量^[14],为优化风功率预测效果,需根据 IMF 时序特征为不同类型的 IMF 分量建立不同的预测模型。本研究通过复杂度和持续相关性结合形成的复合指标为 IMF 分类。

复杂度指标可以衡量序列的规律性。本研究

选取 C_0 复杂度作为复杂度指标,它的基本原理是将时间序列分解成规则部分和不规则部分,其测度值为序列中非规则部分能量所占比例,测度值越大,表示序列越复杂。相较于样本熵或模糊熵仅简单地考虑序列整体的熵值或模糊度量, C_0 复杂度算法在衡量序列复杂度时能够更好地捕捉其非线性部分。

持续相关性指标可以衡量数据点之间的关系,本研究选取 Hurst 指数^[16],其基于尺度分析的方法能够捕捉时间序列在不同尺度下的统计特征。Hurst 指数在 0 到 1 之间取值,Hurst 指数等于 0.5 时表示序列具有随机游走的特性;大于 0.5 时表示时间序列具有持续相关性,取值越接近 1 趋势越明显;小于 0.5 表示时间序列具有反持续相关性,Hurst 指数越趋近于 0 序列越表现为噪声。本研究采用 R/S 分析法计算 Hurst 指数。

由于 C_0 复杂度和 Hurst 指数的取值范围均为 0 到 1,无需进行归一化,且两者对于风功率预测而言具有同等重要性,故复合指标 I 的计算如式(1)所示。

$$I = C_0 \times (1 - H) \quad (1)$$

式中, C_0 表示 IMF 的复杂度; H 为各个 IMF 对应的 Hurst 指数, $1 - H$ 反映的是 IMF 的“非持续相关性”, $1 - H$ 越小则序列趋势越明显。从式(1)可见,当 C_0 较大且 Hurst 指数较小时,复合指标 I 较大,表示序列复杂且趋势不明显;复合指标 I 较小,表示序列简单且趋势明显。

本研究采用各 IMF 计算所得的复合指标 I 的平均值 I_{aver} 为 IMF 分类的阈值,以实现阈值的自适应调整,避免硬编码阈值的局限性。为了避免多分类存在的边界模糊性问题,对分解所得的 IMF 进行二分类,将 $I < I_{\text{aver}}$ 的 IMF 分量归为简单趋势类分量,将 $I \geq I_{\text{aver}}$ 的 IMF 分量归为复杂变化类分量。分类复合指标 I 的引入实现了 IMF 分类,以改进 VMD 技术使其在风功率预测中的性能更佳,继而为后续 Stacking 集成学习策略中机器学习器的选取提供指引。

2.2 基于 Stacking 集成学习策略的风功率预测框架

基于 Stacking 集成学习的风功率预测框架通

过元学习器 CNN 学习基学习器 LSTM 和 LSTM-Attention 预测值对最终预测结果的贡献率,以提高预测模型的性能。

2.2.1 Attention 机制

对于复杂变化分量,本研究在 LSTM 模型中引入 Attention 机制,使模型能够聚焦于对预测目标更重要的时间步。Attention 机制先利用评分函数计算查询向量与键向量的相关性,再对结果进行归一化,得到分布权重;最后,根据权重系数进行加权求和。注意力分数 S_i 的计算公式为:

$$S_i(\mathbf{Q}, K_i) = \mathbf{v}^T \tanh(\mathbf{W}\mathbf{Q} + \mathbf{U}K_i) \quad (2)$$

式中, \mathbf{Q} 为查询向量; K_i 为输入序列 Source 的第 i 个键向量; \mathbf{v}^T 为可学习的权重向量; \mathbf{W} 、 \mathbf{U} 均为可学习的权重矩阵。

通过 softmax 函数内在机制突出重要元素的权重,计算注意力分布权重 α_i :

$$\alpha_i = \text{softmax}(S_i) = e^{S_i} / \sum_{i=1}^n e^{S_i} \quad (3)$$

根据第 i 个值向量 value_i 对应的分布权重 α_i ,对二者加权求和得到 Attention 数值,计算公式为:

$$\text{Attention}(\mathbf{Q}, \text{Source}) = \sum_{i=1}^n (\alpha_i \cdot \text{value}_i) \quad (4)$$

2.2.2 预测流程

基于改进型变分模态分解和集成学习的超短期风功率预测框架的计算步骤为如下。

第 1 步,对历史风功率序列进行清洗,再利用 VMD 将其分解为 k 个 IMF 分量 ($\text{IMF}_1, \text{IMF}_2, \dots, \text{IMF}_k$)。

第 2 步,计算各个 IMF 的 C_0 值和 Hurst 指数并构建 IMF 分类复合指标,将 IMF 分量划分为简单趋势类分量 ($\text{IMF}_1, \text{IMF}_2, \dots, \text{IMF}_m$) 和复杂变化类分量 ($\text{IMF}_{m+1}, \text{IMF}_{m+2}, \dots, \text{IMF}_k$),以实现 VMD 技术的改进。

第 3 步,对简单趋势分量和复杂变化分量分别划分训练集和测试集,并分别构建 LSTM 和 LSTM-Attention 模型作为基学习器进行训练,得到各 IMF 分量在训练集和测试集上的初次预测结果,再将所有分量初次预测结果和分解前历史序列初次预测结果对应的真实值按训练集和测试集分别组合,形成训练集元特征和测试集元特征,

作为元学习器 CNN 的输入。

第 4 步,将训练集元特征输入 CNN 进行训练,将测试集元特征输入训练完成的 CNN 模型中进行预测,从而得到最终的预测结果 \hat{y}_{final} 。

3 算例分析

3.1 实验设置

3.1.1 数据描述及预处理

为验证所提预测框架的有效性,采用俄罗斯某风电场的 1 000 条历史数据作为样本,按 8 : 2 划分训练集和测试集,算例涵盖了提前 15 min 单步预测和提前 1 h 多步预测。为减少数据质量对预测的影响,对历史风功率序列进行数据清洗,同时采用 Min-Max 法对数据进行归一化,如式(5)所示。

$$\tilde{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中, \tilde{x}_i 为第 i 个归一化后的数据; x_{\min} 和 x_{\max} 分别为该序列中的最小值和最大值。

3.1.2 实验平台及参数设置

仿真平台采用 Windows 11 系统, CPU 为 Intel Core i7-8750H 2.20GHz, GPU 为 Nvidia GeForce GTX 1060,模型通过 Python 的 Pytorch 框架实现。参数设置为: LSTM 及 LSTM-Attention 神经元数为 100,激活函数为 ReLU, Attention 机制层数为 20,迭代次数为 150 次,损失函数为 MSE,优化器为 Adam。

3.1.3 仿真评价指标

采用均方根误差 (root mean squared error, RMSE) e_{RMSE} 、平均绝对误差 (mean absolute error, MAE) e_{MAE} 、拟合系数 R^2 作预测结果评价指标。具体公式为:

$$e_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

$$e_{\text{MAE}} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

其中, n 为样本数量; y_i 为第 i 个样本的实际值; \hat{y}_i 为第 i 个样本的预测值; \bar{y} 为所有样本平均值。

3.2 结果分析

3.2.1 VMD 分解的效果分析

模态数 K 设置不当会导致 VMD 过分解或欠分解,如表 2 所示,当 $K \leq 6$ 时,各 IMF 中心频率

最大值随分解深入显著增长;当 $K \geq 6$ 时,IMF7 和 IMF8 的中心频率最大值增幅仅为 0.000 86 和 0.000 94,表明分解趋于饱和。本研究通过对比各 IMF 中心频率的相似性确定 K 值,定为 6。

表 2 经 VMD 分解所得各模态分量的中心频率

Tab.2 Center frequencies of each modal component obtained through VMD decomposition

K	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
1	0.000 70							
2	0.000 63	0.048 37						
3	0.000 24	0.008 60	0.050 60					
4	0.000 23	0.008 47	0.045 28	0.072 79				
5	0.000 23	0.008 42	0.043 52	0.064 52	0.103 91			
6	0.000 23	0.008 41	0.043 22	0.063 55	0.098 75	0.176 09		
7	0.000 23	0.008 38	0.041 98	0.060 01	0.083 01	0.111 47	0.176 95	
8	0.000 23	0.007 85	0.019 23	0.044 51	0.062 34	0.084 77	0.112 43	0.177 03

为验证 VMD 分解的有效性,采用 LSTM、EMD-LSTM、CEEMD-LSTM 和 VMD-LSTM 4 种模型进行单步预测对比,预测曲线如图 4 所示。从图 4 可见,VMD-LSTM 的预测结果与真实值最为接近。




图 4 各模型单步预测结果

Fig.4 Single step prediction results of each model

3.2.2 IMF 分类预测的效果分析

各个 IMF 的 C_0 复杂度测度值、Hurst 指数及复合分类指标 I 的具体计算数值如表 3 所示。

由表 3 可知,若仅依据 C_0 复杂度测度值,则将 $C_0 < 0.5$ 的 IMF1 ~ IMF3 归为简单趋势分量,IMF4 ~ IMF6 归为复杂变化分量;若仅依据 Hurst 指数值,则将 Hurst 值趋近于 1 的 IMF1 归为简单趋势分量,IMF2 ~ IMF6 为复杂变化分量。根据所提的改进型 VMD 的 IMF 分类方法, $I_{aver} = 0.267 03$,则将 $I < I_{aver}$ 的 IMF1 ~ IMF2 归为简单趋势分量, $I > I_{aver}$ 的 IMF3 ~ IMF6 归为复杂变化分量。

表 3 各 IMF 分量的 C_0 、Hurst 指数及复合指标计算结果

Tab.3 Calculation results of C_0 、Hurst index and composite indicators for each IMF component

IMF	C_0	Hurst 指数	I
1	0.094	0.994	0.000 56
2	0.125	0.486	0.064 25
3	0.305	0.115	0.269 93
4	0.510	0.291	0.361 59
5	0.596	0.320	0.405 28
6	0.710	0.295	0.500 55

为验证 IMF 分类复合指标 I 对预测性能的影响,单独采用 C_0 和 Hurst 两个单指标与之作为对比分别进行风功率单步及多步预测,预测结果如图 5 所示,预测结果评价指标分别如表 4 和表 5 所示。

表 4 3 种 IMF 分类方法对应单步预测结果的评价指标
Tab.4 Evaluation metrics for single-step prediction results corresponding to three IMF classification methods

预测模型	e_{RMSE}/MW	e_{MAE}/MW	R^2	耗时/s
C_0 分类法	0.791 6	0.620 3	0.990 4	78.141 2
Hurst 指数法	0.713 2	0.581 0	0.981 5	143.327 1
基于 I 的 IMF 分类法	0.697 6	0.499 8	0.981 3	100.621 0




图 5 3 种 IMF 分类方法对应的预测结果

Fig.5 Prediction results corresponding to three IMF classification methods

表 5 3 种 IMF 分类方法对应多步预测结果的评价指标
Tab.5 Evaluation metrics for multi-step prediction results corresponding to three IMF classification methods

预测模型	e_{RMSE}/MW	e_{MAE}/MW	R^2	耗时/s
C_0 分类法	1.496 3	1.109 6	0.930 1	113.428 9
Hurst 指数法	1.410 6	0.887 0	0.943 5	264.365 3
基于 I 的 IMF 分类法	1.301 4	0.812 7	0.961 4	161.655 4

结合图 5 及表 4、表 5 可知,在单步预测中,相较于 C_0 分类法,基于复合指标 I 的 IMF 分类法耗时增加 22.479 8 s,但精度显著提升;与 Hurst 指数法相比,精度相近,但耗时减少 29.80%。在多步预测中, C_0 分类法耗时最少,但 e_{RMSE} 增大 13.03%,因其将高复杂度的 IMF3 误归为简单趋势序列,导致 LSTM 模型无法充分挖掘其规律,精度下降,故不可取;与 Hurst 指数法相比,基于复合指标 I 的 IMF 分类法在 e_{RMSE} 和 e_{MAE} 上分别提升了 7.74% 和 8.38%, R^2 增加了 0.0179,耗时减少 38.85%,因 Hurst 指数法将较简单的 IMF2 误归为复杂分量,导致 LSTM-Attention 模型过度关注细节而忽略主要趋势,影响精度并增加耗时。综上,

基于复合指标 I 的 IMF 分类法在精度和效率上均具有明显优势。

3.2.3 Stacking 集成学习策略的效果分析

为验证基于 Stacking 集成学习策略的重构性能,采用直接叠加重构法和遗传算法优化变权重组合重构法进行对比,分别开展风功率单步及多步预测,对应的结果如图 6、图 7 及表 6、表 7 所示。

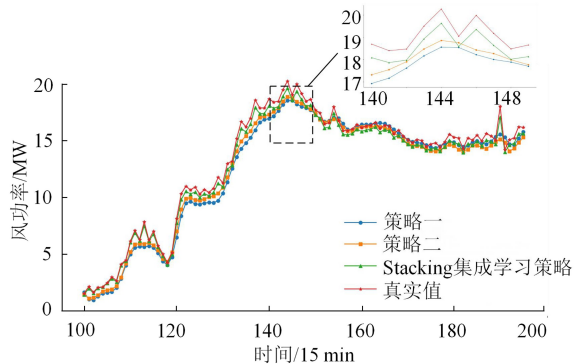


图 6 单步预测结果

Fig.6 Single-step prediction results

表 6 各模型单步预测结果评价指标

Tab.6 Evaluation indicators for single-step prediction results of each model

预测模型	e_{RMSE}/MW	e_{MAE}/MW	R^2	耗时/s
策略一	0.693 7	0.471 6	0.987 2	102.285 0
策略二	0.660 9	0.451 1	0.989 9	162.103 8
Stacking 集成学习策略	0.642 1	0.436 8	0.998 2	115.729 1

如图 6 及表 6 所示,Stacking 集成学习策略预测值与真实值拟合度最高,因 Stacking 集成学习通过元学习器 CNN 有效学习各 IMF 预测值与真实值的关系,输出更精准的预测结果。直接叠加重构法因放大各 IMF 预测误差导致精度较低,变权重组合法虽优于直接叠加,但精度仍不及所提策略,且耗时增加 28.61%。因此,所提策略在风功率单步预测中性能最佳。

由图 7 及表 7 可知,Stacking 集成学习策略的预测曲线与真实值吻合度显著高于策略一和策略二。与效果较好的策略二相比,Stacking 集成学习策略在 e_{RMSE} 上改善了 10.63%、 e_{MAE} 提升了 7.24% 及 R^2 增加了 0.0281,耗时减少了 31.69%,表明所提策略在多步预测中也具有较好的鲁棒性。




图 7 多步预测结果

Fig.7 Multi-step prediction results

表 7 各模型多步预测结果评价指标

Tab.7 Evaluation indicators for multi-step prediction results of each model

预测模型	e_{RMSE}/MW	e_{MAE}/MW	R^2	耗时/s
策略一	1.520 1	1.110 2	0.919 7	163.133 2
策略二	1.310 9	0.843 9	0.939 8	261.743 0
Stacking 集成学习策略	1.171 5	0.782 8	0.967 9	178.807 4

参考文献:

- [1] 姚良忠,朱凌志,周明,等. 高比例可再生能源电力系统的协同优化运行技术展望[J]. 电力系统自动化,2017,41(9):36-43.
- [2] 钟吴君,李培强,涂春鸣. 基于尾流关联的动态超图风电功率超短期预测方法[J/OL]. 中国电机工程学报,2024:1-18. (2024-05-28)[2024-09-15]. <https://kns.cnki.net/kcms/detail/11.2107.tm.20240528.0953.003.html>.
- [3] LIU H Y, HAN H, SUN Y, et al. Short-term wind power interval prediction method using VMD-RFG and Att-GRU[J]. Energy, 2022, 251: 123807.
- [4] 胡威,张新燕,郭永辉,等. 基于游程检测法重构 CEEMD 的短时风功率预测[J]. 太阳能学报, 2020, 41(11): 317-325.
- [5] 任东方,马家庆,何志琴,等. 基于 AVMD-CNN-GRU-Attention 的超短期风功率预测研究[J]. 太阳能学报, 2024, 45(6): 436-443.
- [6] 赵征,汪向硕. 基于 CEEMD 和改进时间序列模型的超短期风功率多步预测[J]. 太阳能学报, 2020, 41(7): 352-358.
- [7] 文博,陈芳芳,胡道波,等. 基于完全集成经验模态分解和模糊熵分频的短期风电功率预测[J]. 科学技术与工程, 2023, 23(25): 10835-10845.
- [8] 刘纯,范高峰,王伟胜,等. 风电场输出功率的组合预测模型[J]. 电网技术, 2009, 33(13): 74-79.
- [9] 张亚超,刘开培,秦亮. 基于 VMD-SE 和机器学习算法的短期风电功率多层次综合预测模型[J]. 电网技术, 2016, 40(5): 1334-1340.
- [10] 崔树银,汪昕杰. 基于特征工程的集成学习短期光伏功率预测[J]. 科学技术与工程, 2022, 22(2): 532-539.
- [11] 王彪,吕洋,陈中,等. 考虑信息时移的分布式光伏机理-数据混合驱动短期功率预测[J]. 电力系统自动化, 2022, 46(11): 67-74.
- [12] 江南,王昌,杜永峰. 分形的成因及影响探析:纪念芒德勃罗诞辰 100 周年[J]. 自然辩证法研究, 2024, 40(9): 115-122.
- [13] 何鹏,孙瑞山. 中国民航典型征候的趋势研究[J]. 中国安全科学学报, 2023, 33(7): 133-139.
- [14] 杨晶显,张帅,刘继春,等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测[J]. 电力系统自动化, 2021, 45(3): 174-182.
- [15] 沈恩华,蔡志杰,顾凡及. C0 复杂度的数学基础[J]. 应用数学和力学, 2005, 26(9): 1083-1090.
- [16] 王启云,郑中团. CEEMDAN-HURST 算法在新冠疫情预测中的应用[J]. 计算机工程与应用, 2023, 59(7): 261-268.

(责任编辑:方素华)

4 结论

为提升超短期风功率预测的精度和效率,本研究提出基于改进型 VMD 和 Stacking 集成学习的超短期风功率预测方法,结论如下:

1)所提的改进型 VMD 通过 IMF 分类复合指标能够实现更准确的分类,在 IMF 分类预测效果分析的多步预测中,相较于单指标分类法,其精度提升约 8%,效率提升约 40%。

2)实验结果表明,所提基于 Stacking 集成学习的超短期风功率预测框架对提升风功率预测精度、减少风功率预测耗时的效果较为显著,在多步预测中分别提升了约 7%和 31%。

3)本研究中 VMD、LSTM、LSTM-Attention、CNN 等技术的参数均是基于经验调试而定,需要耗费大量时间成本和计算成本,下一步工作方向为寻找合适的算法为全局参数进行寻优,从而进一步提升预测精度和效率。