

基于VMD-LSTM的超短期风向多步预测

李秀昊^{1,✉}, 刘怀西¹, 张智勇², 张敏¹, 吴迪¹, 苗得胜¹

(1. 明阳智慧能源集团股份公司, 广东中山 528437; 2. 中国南方电网广东中山供电局, 广东中山 528437)

摘要: [目的]为准确预测未来4 h风向, 提出一种基于VMD-LSTM (Variational Mode Decomposition-Long Short-Term Memory) 的超短期风向多步预测方法。[方法]采集明阳智能某风电场3个风电机组的风向序列, 对其进行预处理及时序分析; 基于自相关函数(Autocorrelation Function, ACF)计算风向不同时期的相关性, 以选取风向序列的特征长度; 采用变分模态分解(Variational Mode Decomposition, VMD)将风向序列分解为相对稳定的模态信号, 通过最小样本熵确定分解的子模态数, 并对分解后的模态信号分别建立预测模型, 进行超短期风向24步预测; 重构风向序列, 叠加各分量预测结果。[结果]结果表明, VMD-LSTM在4个季度的24步风向预测的绝对平均误差(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)分别为8.430°、16.870°、9.155, 且在每个季度不同时间尺度的各个误差评价指标均优于其他常见的数据建模方法。[结论]所提算法可满足风电场的实际生产中优化控制偏航角的要求。

关键词: 风向; 多步预测; 变分模态分解; 样本熵; 长短期记忆

中图分类号: TK89; TM614 文献标志码: A

文章编号: 2095-8676(2023)01-0029-10

开放科学(资源服务)二维码:



Very Short-Term Wind Direction Multistep Forecast Based on VMD-LSTM

LI Xiuhao^{1,✉}, LIU Huaixi¹, ZHANG Zhiyong², ZHANG Min¹, WU Di¹, MIAO Desheng¹

(1. Mingyang Smart Energy Group Limited, Zhongshan 528437, Guangdong, China;

2. China Southern Power Grid Guangdong Zhongshan Power Supply Bureau, Zhongshan 528437, Guangdong, China)

Abstract: [Introduction] In order to accurately forecast the wind direction in the next 4 hours, a very short-term wind direction multistep forecast algorithm based on VMD-LSTM (Variational Mode Decomposition-Long Short-Term Memory) is proposed. [Method] Wind direction sequence was collected from 3 wind turbines of a wind farm of Mingyang Smart Energy Group for preprocessing and analysis. The correlation of wind direction in different periods was calculated using the autocorrelation function (ACF) to select the characteristic length of wind direction sequence. Based on variational mode decomposition (VMD), the wind direction sequence was decomposed into relatively intrinsic mode functions, the number of which was determined by minimum sample entropy. Models were build for each intrinsic mode function to make very short-term wind direction 24-step forecast. Finally, the wind direction sequence was reconstructed from the forecasted intrinsic mode functions. [Result] The results obtained demonstrate that the average MAE (Mean Absolute Error), RMSE (Root Mean Square Error) and MAPE (Mean Absolute Percentage Error) of the 24-step wind direction forecast based on VMD-LSTM in 4 quarters are 8.430°, 16.870° and 9.155, respectively. The algorithm performs better than other common data modeling methods regarding each error evaluation index at different time scales in each quarter. [Conclusion] The proposed algorithm can optimize the control yaw angle in the actual production of wind farms.

Key words: wind direction; multistep forecast; Variational Mode Decomposition(VMD); Sample Entropy(SE); Long Short-Term Memory(LSTM)

2095-8676 © 2023 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI. This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

0 引言

在风力发电中,偏航系统依据风向进行对风操作,准确对风可以降低风力发电机组的载荷、提高风能利用率,进而提高发电量,直接影响机组的经济性和安全性^[1]。而风向却是随机的、不稳定的,这使得偏航系统的对风存在一定的误差和滞后性,继而导致偏航系统偏航动作频繁。因此,风向的准确预测可以提高偏航系统的对风精度、减小偏航滞后性,有利于风电场结合风向变化趋势制定偏航控制策略,进而对偏航优化提供保障,对风电企业经济、安全生产具有较大的工程实践指导意义。

风向建模方法主要分为物理建模法、统计建模法和数据驱动建模法。物理建模法通常利用数值天气预报(Numerical Weather Prediction,NWP)数据进行建模^[2],模型计算量大,主要用于长期预测。统计建模法一般使用时间序列建模,主要包括自回归移动平均模型(Autoregressive Moving Average model, ARMA)^[3]、自回归差分移动平均模型(Autoregressive Integrated Moving Average model, ARIMA)^[4]、自回归条件异方差模型(Autoregressive Conditional Heteroskedasticity model, ARCH)^[5]等,相比于物理模型,统计建模法不用求解复杂的物理模型,计算效率高,常用于短期预测,但无法准确地描述非线性数据。由于风向数据具有非线性、非平稳性、随机性等特点,数据驱动模型可有效地处理复杂时序预测,BP 神经网络^[6]、支持向量机^[7]等模型都取得不错的效果。张亚超^[8]等提出一种基于 VMD-SE 和基模型的自适应多层级综合预测模型,可实现短期风电功率 3 步预测。但传统的浅层神经网络难以充分挖掘数据的深层特征,导致模型预测精度受限。深度学习以其强大的特征提取能力,在时序预测等任务上取得巨大的成功。唐振浩^[9]等提出一种基于数据解析的混合建模算法(Data Analytics based Hybrid Algorithm, DAHA),可实现风向的单步预测。林涛^[10]等提出 1 种变分模态分解(VMD)和蝙蝠算法(Bat Algorithm, BA)优化长短记忆(LSTM)神经网络的短期风向预测模型,可提前预测未来 5 min、15 min 和 30 min 的风向。向玲^[11]等提出一种变分模态分解(VMD)-模糊信息粒化(Fuzzy Information Granulation, FIG)和参数优化门控循环单元(Gate Recurrent Unit, GRU)的风速多步

区间预测方法,可实现风速 3 步区间预测。由于风向具有强波动性和随机性等特点,但现有文献进行超短期风向预测时多为单步预测,且风向多步预测中预测步长较短,难以满足风电场的实际生产需求。

为此,针对超短期风向多步准确预测,本文提出一种基于 VMD-LSTM 的风向多步预测算法,准确预测未来 4 h 的风向。首先,通过自相关函数计算风向不同时期之间的相关性,以选取模型最佳的风向序列输入长度;然后,针对风向数据波动性、随机性的特点,采用变分模态分解法将风向序列分解为相对稳定的模态信号,通过最小样本熵确定分解的子模态数,并对分解后的模态信号分别建立超短期风向预测模型进行预测;最后,重构风向序列,叠加各分量预测结果,实现超短期风向 24 步预测。

1 风向特征分析

明阳智能某风电场 3 个风电机组(1#、2#、3#)1 年风向数据的风玫瑰图如图 1 所示。其中,扇形区域的颜色表示不同的风速大小,长度表示风向的频率。

由图 1 所示及统计可知,1#、2#号风机的主导风向为东,3#号风机的主导风向为东南偏东;1#、2#、3#号风机的盛行风向区间为(67.5°, 112.5°),盛行风频率分别为 40.31%、39.96%、40.61%。虽然 1#、2#、3#号风机同处一风场,但受风机排布位置及尾流的影响^[12],同一风场不同风机的风向也有所差别。由此可见,风向存在较大的随机性与不稳定性,进一步增大了风向预测的难度。

2 风向建模

2.1 基于 ACF 的模型特征输入长度选择

不同的序列输入长度对模型的预测结果有一定影响。模型输入的序列长度过短,难以表征序列特征,降低模型预测的准确率;输入序列过长导致信息冗余,降低模型的建模效率。本文采用自相关函数计算前 k 个时刻($k > 0$)的风向 x_{t-k} 与当前时刻的风向 x_t 之间的相关性,以选取最佳的风向序列输入长度。

自相关函数(Autocorrelation Function, ACF)用于度量同一事件在不同时期之间的相关性程度。对于时间序列 $\{X_t\}$, ACF 度量时间序列中每隔 k 个时间

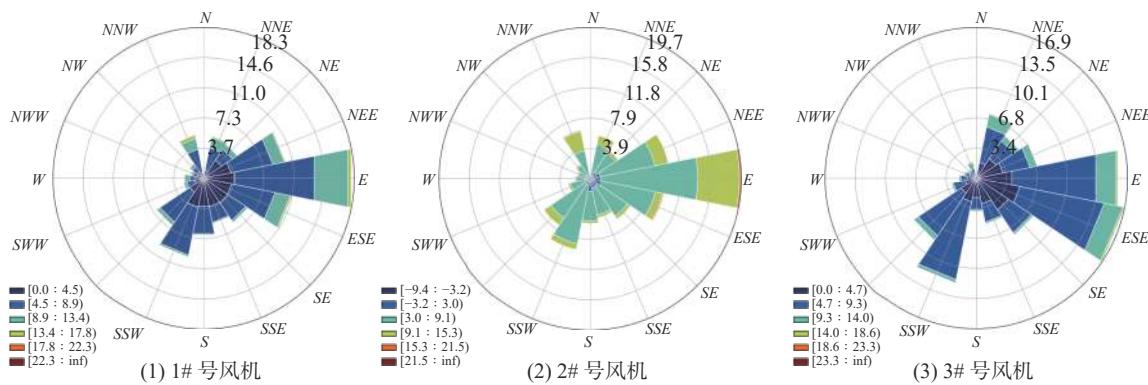


图 1 全年风向玫瑰图

Fig. 1 Year-round wind rose map

单位(x_t 和 x_{t-k})的观测值之间的相关性,计算公式如下:

$$\text{ACF} = \frac{\sum_{t=k+1}^n (x_t - \bar{x})(x_{t-k} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$

式中:

\bar{x} ——变量 x 的平均值。

如图2所示,横坐标表示时间滞后长度,纵坐标表示滞后为 k 个时刻的风向序列与当前序列的相关性。本文计算了72个样本点的相关性,随着 k 的增大,历史风向与当前风向的相关性逐渐减弱,当 $k > 35$ 时其自相关系数小于0.6。为了兼顾模型的预测精度与效率,选择自相关系数大于0.6的序列。此外,输入序列长度应不少于预测序列长度,本文中预测未来4 h的风向,即输入序列长度应不少于24个样本点。因此,本文选取自相关系数大于0.6的前24个采样点的风向作为模型的输入序列。

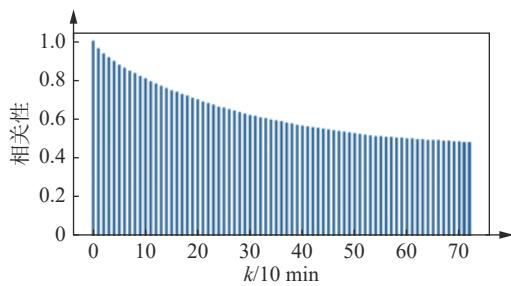


图 2 风向自相关性

Fig. 2 The autocorrelation coefficient of wind direction

2.2 基于 SE-VMD 的特征转换

变分模态分解(Variational Mode Decomposition, VMD)是一种完全内在、自适应、非递归的信号分解

技术^[13],通过求解约束变分问题,将信号转换到频域内分解为 K 个有限带宽的本征模函数(Intrinsic Mode Function, IMF),这种方法可以有效避免经验模态分解(Empirical Mode Decomposition, EMD)和局部均值分解(Local Mean Decomposition, LMD),在分解中由于递归分解模式所造成的包络线估计误差,具备强大的非线性和非平稳性信号处理能力,相比于EMD和集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)等信号分解方法,它在解决信号噪声和避免模态混叠的问题上有显著优势。但VMD分解的IMF子模态数 K 对分解结果有很大的影响:当 K 太小时,分解后的序列会丢失过多信息从而导致模态混叠;当 K 太大时,会出现过度分解的问题。

为了评估序列数据的复杂性,Richman 和 Moornan等^[14]提出样本熵(Sample Entropy, SE),通过度量信号中产生新模式的概率大小来衡量时间序列的复杂性,时间序列越复杂,样本熵的值越大。

针对风向数据波动性、随机性的特点,本文采用VMD对风向序列进行分解,得到多个稳定的子信号,通过最小SE值对VMD进行优化^[15],以获取合适的 K 值。

2.3 基于 LSTM 的风向预测建模

长短期记忆(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络(Recurrent Neural Network, RNN),主要为了解决长序列训练过程中的梯度消失和梯度爆炸问题^[16]。相比于RNN,LSTM能够在更长的序列中有更好的表现。LSTM由多个单元组成,每个LSTM单元包括3个门控系统和1个记忆单元,

具体为:

遗忘门:

$$F_t = \text{sigmoid}(w_{xf}x_t + w_{hf}h_{t-1} + b_f) \quad (2)$$

输入门:

$$I_t = \text{sigmoid}(w_{xi}x_t + w_{hi}h_{t-1} + b_i) \quad (3)$$

输出门:

$$O_t = \text{sigmoid}(w_{xo}x_t + w_{ho}h_{t-1} + b_o) \quad (4)$$

记忆单元状态值:

$$C_t = C_{t-1} \otimes F_t + I_t \otimes \tanh(w_{xc}x_t + w_{hc}h_{t-1} + b_c) \quad (5)$$

LSTM 记忆单元在 t 时刻的输出:

$$h_t = O_t \otimes \tanh(C_t) \quad (6)$$

式(2)~式(6)中, $w(F_t, I_t, O_t, C_t)$ 和 $b(F_t, I_t, O_t, C_t)$ 为三个门控单元和记忆单元的权重和偏置值。

本文采用两层的 LSTM 网络挖掘风向时序序列的深层特征, 每层的神经元个数为 100, 学习率为 0.001, 优化器为 Adam, 迭代次数为 10, 激活函数为 ReLU, 如图 3 所示。

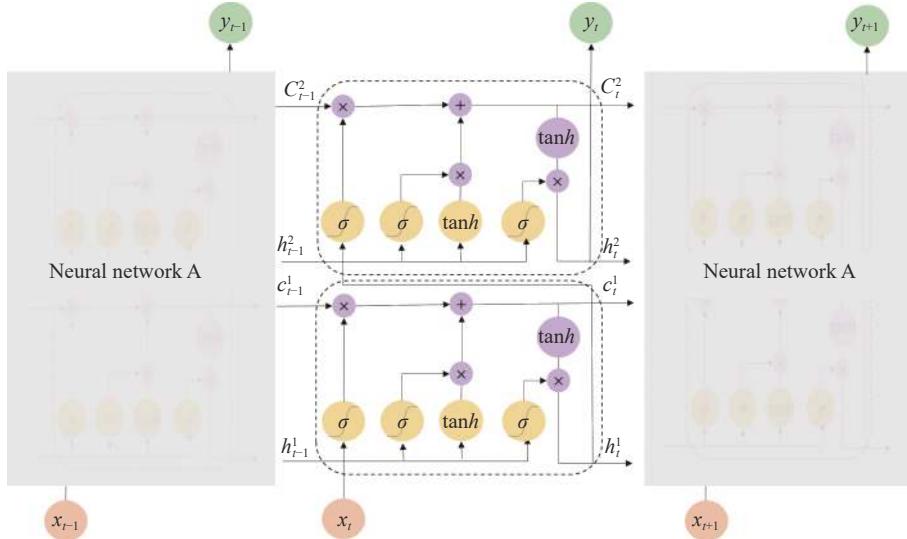


图 3 LSTM 结构
Fig. 3 The structure of LSTM

3 试验结果与分析

3.1 数据预处理

本文采用明阳智能某风电场数据采集与监视控制系统(SCADA)提供的 2021 年风向数据。风向数据来源于 3 个风力发电机(1#、2#、3#), 时间粒度为 10 min, 按季度分为 4 组。为保证时间样本的顺序性, 使用样本总量前 70% 的序列作为训练集, 后 30% 的时间序列作为测试集, 具体如表 1 所示。

表 1 数据集信息
Tab. 1 Dataset information

数据集	数据来源	训练集数量	测试集数量
A	2021/03/01 00:00—2021/03/31 23:50	3 125	1 339
B	2021/06/01 00:00—2021/06/30 23:50	3 024	1 296
C	2021/09/01 00:00—2021/09/30 23:50	3 024	1 296
D	2021/12/01 00:00—2021/12/31 23:50	3 125	1 339

根据 GB/T 37523—2019^[17] 对风向数据进行合理范围筛选, 剔除异常数据值, 使用滑动平均法对缺失数据进行插补; 采用最大-最小归一化方法对风向数据进行处理, 将风向数据映射到 [0,1] 内, 归一化计算如下:

$$y'_t = \frac{y_t - y_{\min}}{y_{\max} - y_{\min}} \quad (7)$$

式中:

y'_t —— t 时刻归一化后的风向数据;
 y_t —— t 时刻的原始风向数据;
 y_{\max} —— 风向序列的最大值;
 y_{\min} —— 风向序列的最小值。

3.2 评价指标

本文采用绝对平均误差(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)作为评价指标, 衡量预测值与真实值的偏离程度、评价数据的变化程度、定量评价预测模型, 其表达式分别为:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{\text{true}} - y_{\text{pre}}| \quad (8)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{true}} - y_{\text{pre}})^2} \quad (9)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{\text{true}} - y_{\text{pre}}}{y_{\text{true}}} \right| \quad (10)$$

式中:

y_{true} —— 真实值;

y_{pre} —— 预测值;

n —— 样本个数。

3.3 预测流程

本文算法流程图如图 4 所示。

具体步骤如下:

- 1) 采集风向序列并对其进行预处理。
- 2) 绘制风向玫瑰图, 分析风向特征。
- 3) 基于 ACF 计算风向不同时期之间的相关性, 选取自相关系数大于 0.6 的前 24 个采样点的风向作为模型的输入序列。
- 4) 采用 VMD 将风向序列分解为相对稳定的模态信号, 通过最小样本熵确定分解的子模态数 K 。
- 5) 对分解后的 K 个模态信号分别建立预测模型, 进行超短期风向多步预测。
- 6) 重构风向序列, 叠加各分量预测结果。

3.4 结果与分析

3.4.1 基于 SE 的 VMD 分解模态数确定

VMD 分解的子模态数 K 直接决定了风向信号分解的好坏, 对预测结果有一定的影响。本文利用 VMD 对风向数据进行分解得到 K 个 IMF, 计算每个 IMF 的 SE 值, 以获得具有最小 SE 的序列作为趋势项, 通过对不同 K 值的最小 SE 值以确定子模态数。本文令 K 取值为 2~10, 如图 5 显示了在取不同 K 值时最小 SE 值和预测绝对平均误差的变化趋势。

由图 5 可知, 随着 VMD 分解的子模态数 K 的增加, 最小样本熵的值减小, 风向预测模型的绝对平均误差 MAE 减小, 并且两者衰减的变化趋势基本保持一致, 表明最小样本熵的值能够有效地表征信号分解能力。当子模态数 K 较小时, 原始风向信号分解不足, 序列趋势项中混入了其他干扰项, 使得 SE 值较

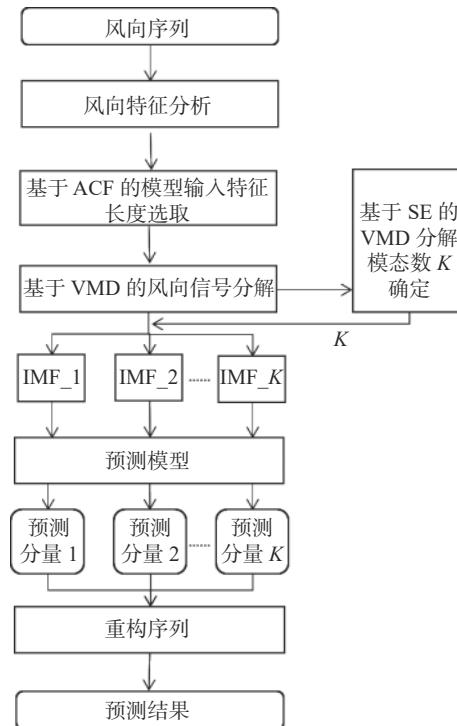


图 4 算法流程图

Fig. 4 Algorithm flowchart

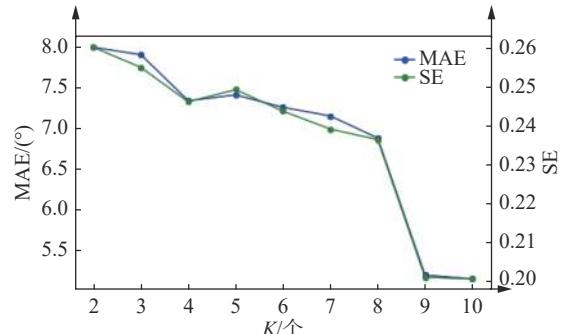


图 5 最小样本熵和绝对平均误差的变化趋势

Fig. 5 Variation trend of minimum sample entropy and absolute mean error

大。随着 K 值的增大, SE 值逐渐变小, 当取得适当的 K 值时, SE 值骤减, 此时再增大分解次数 K , SE 值变化较小, 并且逐渐趋于稳定。因此, 将 SE 骤减趋于稳定的转折点作为 VMD 分解的次数, 以避免过度分解。在本文中, 取 $K=9$, 即利用 VMD 将原始风向信号分解为 9 个子序列, 如图 6 所示。

3.4.2 基于 VMD-LSTM 的风向多步预测

为验证 VMD 分解对预测结果的影响, 进行 VMD 分解前后对比算法建模预测结果的比较。由表 2、

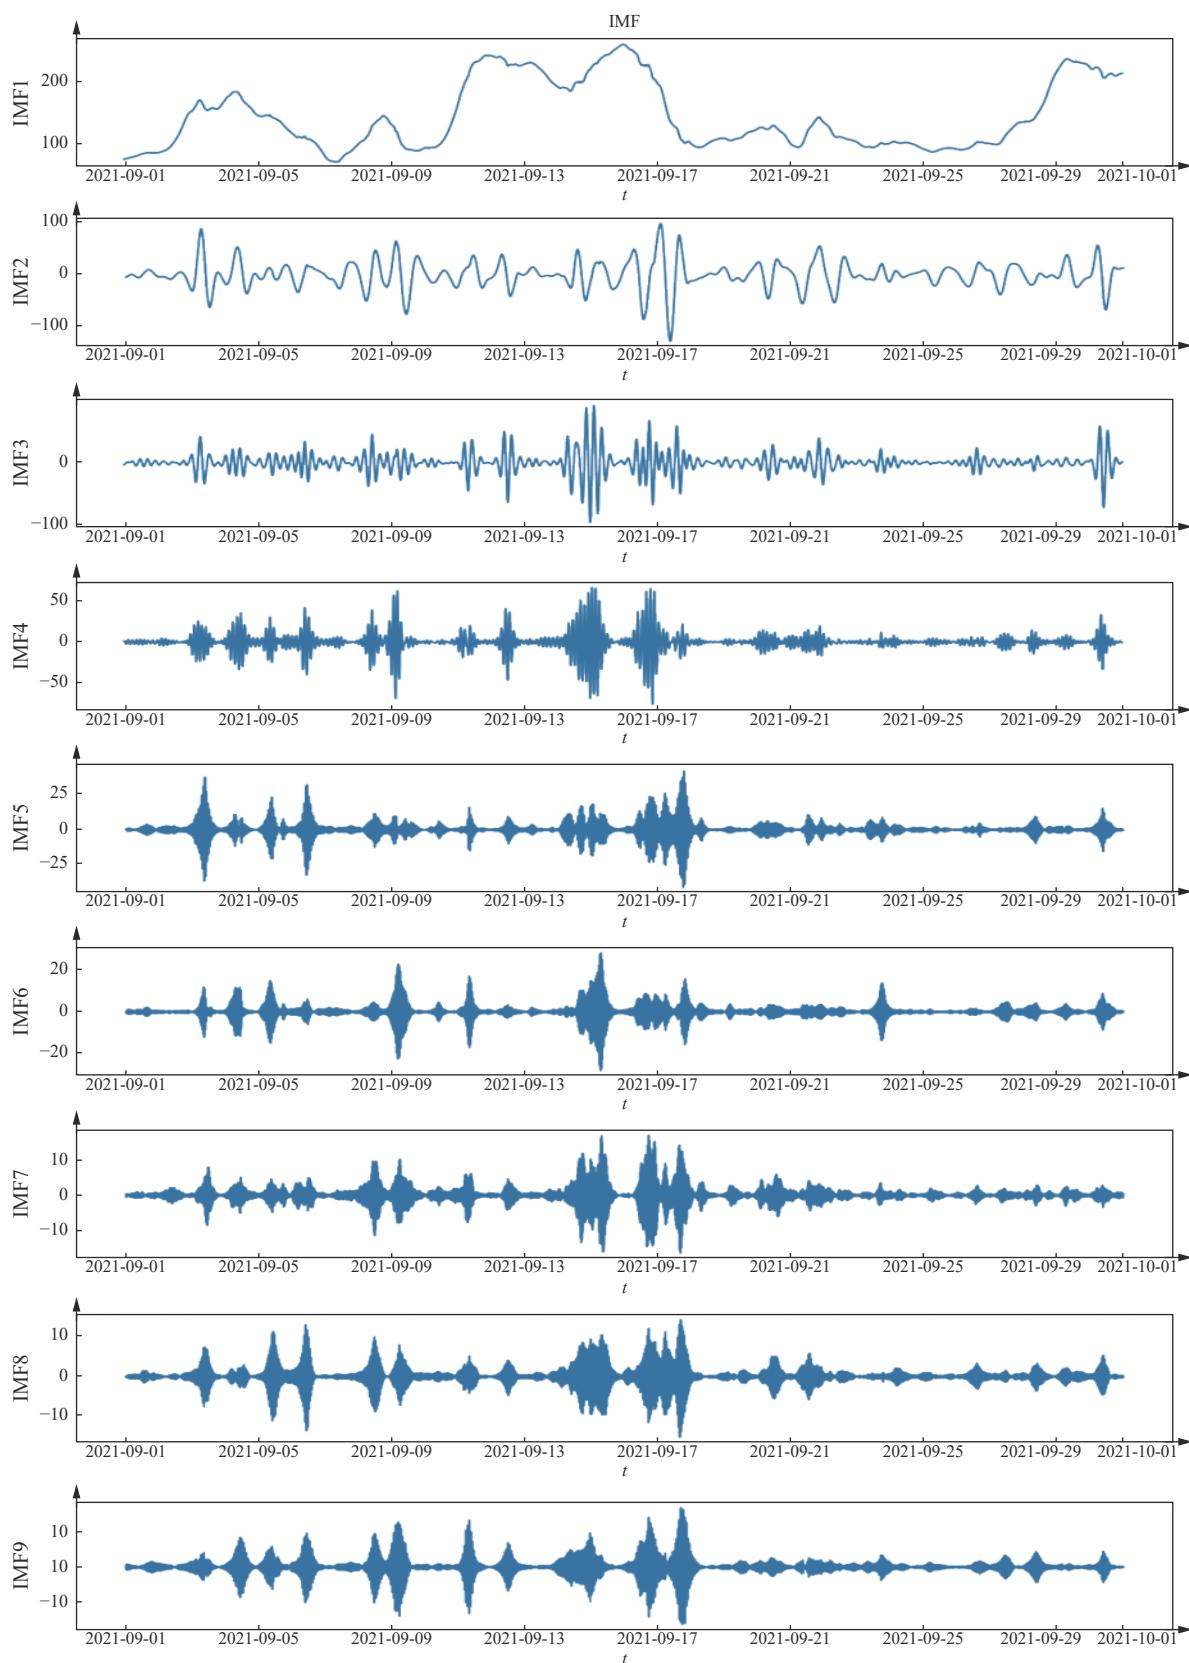


图 6 原始风向信号 VMD 分解
Fig. 6 Original wind direction decomposition by VMD

图 7 和图 8 可知, VMD-LSTM 在 4 个季度的 24 步风向预测的平均 MAE、RMSE、MAPE 为 8.430° 、 16.870° 、 9.155 , 比未分解的 LSTM 模型平均减少 77.91% 、 69.30% 、 69.42% , 因此, VMD 将原始风向序列分解为相对稳定的模态信号, 可以有效地降低风向的非线性、非平稳性和随机性, 提高风向序列预测的准确性。

预测误差随着预测时间的增加而累加, 进而导致误差逐步增大, LSTM 模型平均每步误差增长约为 1.26° , VMD-LSTM 模型误差稳步增长, 增长幅度较小, 平均每步误差增长约为 0.29° , 说明 VMD-LSTM 模型可以有效地降低误差的增长速度, 稳定误差增

长幅度。

3.4.3 风向预测方法比较

不同的预测方法对超短期风向多步预测有一定的影响。本文基于不同季度的风向分别构建 ARMA、RF、VMD-RF、LSTM、VMD-LSTM 模型。

由表 3 和图 9 可知, VMD-LSTM 在每个季度的各个误差评价指标均优于其他算法。VMD-LSTM 模型较表现次好的 VMD-RF 模型, 其平均 MAE、RMSE、MAPE 分别减少 37.19% 、 23.80% 、 26.85% 。通过不同建模算法的试验, 结果表明, VMD-LSTM 在不同季度下的风向具有更高的准确性和较好的预测能力。此外, VMD-LSTM 和 VMD-RF 比未分解的模型 LSTM

表 2 基于 VMD-LSTM 的风向多步预测结果

Tab. 2 Wind direction multistep forecast results based on VMD-LSTM

预测步长	第1季度			第2季度			第3季度			第4季度		
	MAE/(°)	RMSE/(°)	MAPE	MAE/(°)	RMSE/(°)	MAPE	MAE/(°)	RMSE/(°)	MAPE	MAE/(°)	RMSE/(°)	MAPE
1	7.782	15.445	8.137	6.693	11.632	4.704	5.358	8.772	8.772	4.592	15.097	4.983
2	7.712	15.325	8.045	6.549	11.404	4.601	5.316	8.682	8.682	4.553	14.926	4.934
3	7.711	15.338	8.012	6.449	11.315	4.505	5.306	8.571	8.571	4.532	14.730	4.872
4	7.644	15.251	7.912	6.744	11.858	4.688	5.331	8.598	8.598	4.478	14.443	4.788
5	7.674	15.323	7.939	7.353	12.969	4.997	5.460	8.766	8.766	4.421	14.229	4.755
6	7.618	15.312	7.969	7.579	13.206	5.208	5.641	8.991	8.991	4.500	14.472	4.872
7	7.747	15.730	8.152	7.829	13.502	5.413	5.911	9.361	9.361	4.775	15.188	5.213
8	8.140	16.657	8.501	8.085	13.950	5.658	5.855	9.425	9.425	5.127	16.167	5.637
9	8.810	17.957	9.252	8.231	14.118	5.785	6.003	9.750	9.750	5.620	17.848	6.211
10	9.280	18.590	9.591	8.229	14.233	5.793	6.194	10.156	10.156	6.220	19.691	6.790
11	9.842	19.332	10.309	8.355	14.464	5.853	6.494	10.685	10.685	6.736	21.455	7.257
12	10.591	20.647	11.152	8.317	14.432	5.796	6.891	11.286	11.286	7.031	22.352	7.520
13	11.968	23.267	12.449	8.427	14.814	5.864	7.263	11.836	11.836	7.292	22.568	7.639
14	12.890	25.433	13.383	8.610	15.168	6.013	7.977	12.848	12.848	7.674	22.968	7.936
15	13.059	25.331	13.584	8.704	15.388	6.141	7.883	12.827	12.827	8.146	23.452	8.423
16	14.072	26.942	14.886	9.034	15.901	6.422	8.045	13.036	13.036	8.627	24.461	8.829
17	13.607	25.731	14.647	9.428	16.464	6.762	8.462	13.613	13.613	8.440	23.332	8.432
18	13.042	24.306	14.045	10.186	17.584	7.312	8.601	13.710	13.710	8.534	22.889	8.355
19	13.098	24.205	14.089	10.055	17.285	7.258	8.578	13.823	13.823	8.918	23.067	8.585
20	13.292	24.449	14.198	10.285	17.626	7.453	8.756	14.300	14.300	8.786	21.985	8.495
21	13.740	25.289	14.883	10.783	18.253	7.772	9.182	15.181	15.181	8.954	22.006	8.740
22	13.757	25.237	14.869	10.628	18.060	7.722	9.662	16.071	16.071	9.087	21.890	8.988
23	13.977	25.423	15.135	10.412	17.667	7.644	10.011	16.600	16.600	9.457	22.350	9.440
24	13.755	25.003	14.834	10.342	17.657	7.651	10.421	17.371	17.371	10.029	23.166	9.975

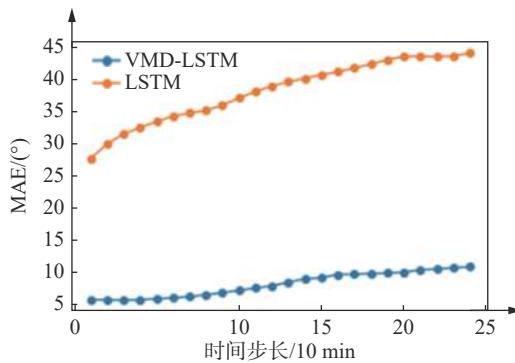


图 7 LSTM 与 VMD-LSTM 预测结果对比

Fig. 7 Comparison of LSTM and VMD-LSTM forecast results

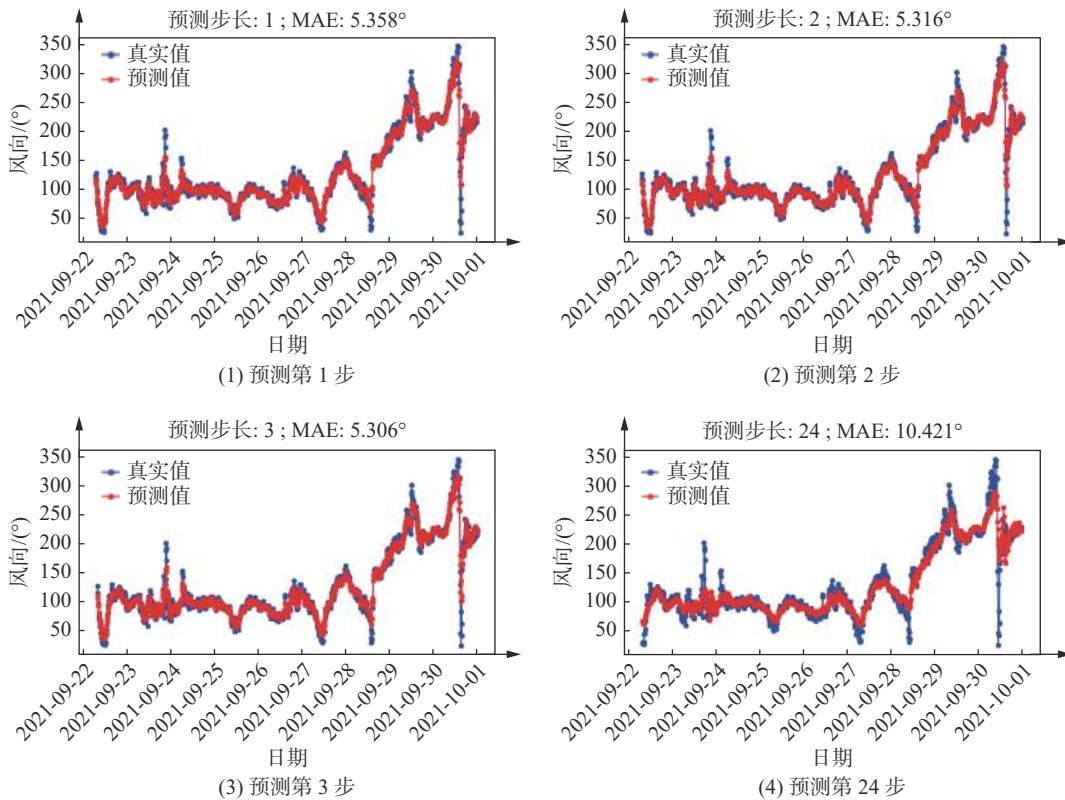


图 8 基于 VMD-LSTM 的风向多步预测结果

Fig. 8 Wind direction multistep forecast results based on VMD-LSTM

差距较小,说明VMD-LSTM可适用于同一风场不同风机的预测,具有良好的泛化能力。

4 结论

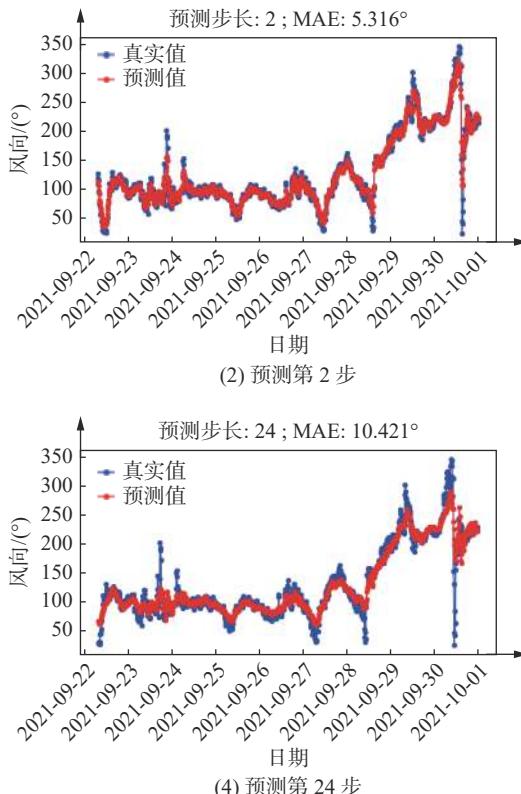
由于风向具有强波动性和随机性等特点,目前的超短期风向预测步长较短,难以满足风电场的实际生产需求。为此,本文提出1种基于VMD-LSTM的风向多步预测算法,通过算例分析,得到以下主要结论:

和RF的MSE分别降低了77.91%和57.86%,说明经过分解后的建模精度有较大幅度的提高,VMD在提取风向趋势信息方面具有较好的能力。

3.4.4 不同风机预测结果

为检验该方法对不同风机的风向预测效果,本文对比分析了同一风场1#、2#、3#号风机,绝对平均误差MAE见表4。

虽然1#、2#、3#号风机同处一风场,但受风机分布位置及尾流的影响,导致不同风机在每个季度的预测结果也有所差异,但不同风机的预测总体误差



1)VMD将原始风向序列分解为相对稳定的模态信号,可以有效地降低风向的非线性、非平稳性和随机性,提高风向序列预测的准确性。利用最小样本熵的值确定VMD分解的子模态数,可优化VMD的风向信号分解性能,提高VMD的风向趋势信息提取能力。

2)针对不同的预测方法对超短期风向多步预测的影响,分别构建ARMA、RF、VMD-RF、LSTM、VMD-LSTM预测模型。比较发现,VMD-LSTM在

表 3 不同方法的风向预测结果

Tab. 3 Wind direction forecast results of different methods

预测模型	季度	MAE/(°)	RMSE/(°)	MAPE
ARMA	1	18.171	36.762	21.131
	2	21.636	37.293	15.900
	3	14.183	25.072	15.230
	4	8.774	27.975	9.853
RF	1	33.897	52.224	30.148
	2	28.189	45.544	19.395
	3	18.734	28.462	19.032
	4	46.554	56.749	56.749
VMD-RF	1	16.130	27.310	17.054
	2	12.909	20.421	9.514
	3	10.786	16.021	11.003
	4	13.857	24.802	12.495
LSTM	1	41.677	61.162	34.512
	2	38.968	59.598	28.449
	3	23.140	33.851	22.536
	4	48.877	65.171	34.266
VMD-LSTM	1	10.867	20.897	11.499
	2	8.638	14.956	6.126
	3	7.275	11.844	11.844
	4	6.939	19.780	7.153

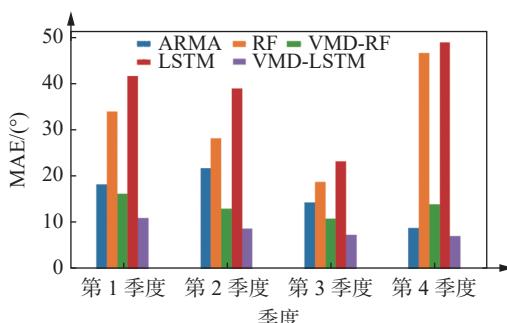


图 9 不同方法的风向预测结果

Fig. 9 Wind direction forecast results of different methods

表 4 不同风机的风向预测结果 MAE

Tab. 4 MAE of wind direction forecast for different wind turbines

风机	(°)				
	第1季度	第2季度	第3季度	第4季度	合计
1#	14.595	8.349	8.492	9.865	10.325
2#	13.345	8.231	9.750	8.927	10.063
3#	12.390	8.954	10.808	8.934	10.271

4个季度的24步风向预测的平均MAE、RMSE、MAPE为8.430°、16.870°、9.155，在每个季度不同时间尺度

的各个误差评价指标均优于其他算法，所提算法可满足风电场的实际生产中优化控制偏航角的要求。

3)由于风向数据具有较大的随机性和不稳定性等特点,且受风机排布位置及尾流的影响,进一步增大了风向预测的难度。通过对不同风机的预测结果,证明了模型的鲁棒性,具有良好的泛化能力。

参考文献:

- [1] 张东东,崔新维. BP神经网络在风力发电机风向预测中的应用 [J]. 太阳能, 2015(3): 47-49. DOI: 10.3969/j.issn.1003-0417.2015.03.011.
- ZHANG D D, CUI X W. Application of BP neural network in wind direction forecast of wind turbine [J]. Solar Energy, 2015(3): 47-49. DOI: 10.3969/j.issn.1003-0417.2015.03.011.
- [2] CHENG W Y, LIU Y B, BOURGEOIS A J, et al. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation [J]. Renewable Energy, 2017, 107: 340-351. DOI: 10.1016/j.renene.2017.02.014.
- [3] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction [J]. Applied Energy, 2011, 88(4): 1405-1414. DOI: 10.1016/j.apenergy.2010.10.031.
- [4] KAVASSERI R G, SEETHARAMAN K. Day-ahead wind speed forecasting using f-ARIMA models [J]. Renewable Energy, 2009, 34(5): 1388-1393. DOI: 10.1016/j.renene.2008.09.006.
- [5] AMBACH D, SCHMID W. A new high-dimensional time series approach for wind speed, wind direction and air pressure forecasting [J]. Energy, 2017, 135(17): 833-850. DOI: 10.1016/j.energy.2017.06.137.
- [6] WANG S X, ZHANG N, WU L, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method [J]. Renewable Energy, 2016, 94: 629-636. DOI: 10.1016/j.renene.2016.03.103.
- [7] KHOSRAVI A, KOURY R N N, MACHADO L, et al. Prediction of wind speed and wind direction using artificial neural network, support vector regression and adaptive neuro-fuzzy inference system [J]. Sustainable Energy Technologies and Assessments, 2018, 25: 146-160. DOI: 10.1016/j.seta.2018.01.001.
- [8] 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. DOI: 10.13335/j.1000-3673.pst.2016.05.007.
- ZHANG Y C, LIU K P, QIN L. Short-term wind power multi-leveled combined forecasting model based on Variational Mode Decomposition-Sample entropy and machine learning algorithms [J]. Power System Technology, 2016, 40(5): 1334-1340. DOI: 10.13335/j.1000-3673.pst.2016.05.007.
- [9] 唐振浩,赵赓楠,曹生现,等.一种基于数据解析的混合风向预测算法 [J]. 太阳能学报, 2021, 42(9): 349-356. DOI: 10.1007/s10008-021-0560-1.

- [19912/j.0254-0096.tynxb.2020-0119.]
TANG Z H, ZHAO G N, CAO S X, et al. A data analytic based hybrid wind direction prediction algorithm [J]. *Acta Energiae Solaris Sinica*, 2021, 42(9): 349-356. DOI: [10.19912/j.0254-0096.tynxb.2020-0119](https://doi.org/10.19912/j.0254-0096.tynxb.2020-0119).
- [10] 林涛, 王建君, 张达. 基于VMD-BA-LSTM的短期风向预测研究 [J]. *高技术通讯*, 2021, 31(6): 653-659. DOI: [10.3772/j.issn.1002-0470.2021.06.010](https://doi.org/10.3772/j.issn.1002-0470.2021.06.010).
- LIN T, WANG J J, ZHANG D. Short-term wind direction prediction research based on VMD-BA-LSTM [J]. *Chinese High Technology Letters*, 2021, 31(6): 653-659. DOI: [10.3772/j.issn.1002-0470.2021.06.010](https://doi.org/10.3772/j.issn.1002-0470.2021.06.010).
- [11] 向玲, 李京蓄, 王朋鹤, 等. 基于VMD-FIG和参数优化GRU的风速多步区间预测 [J]. *太阳能学报*, 2021, 42(10): 237-242. DOI: [10.19912/j.0254-0096.tynxb.2019-1083](https://doi.org/10.19912/j.0254-0096.tynxb.2019-1083).
XIANG L, LI J X, WANG P H, et al. Wind speed multistep interval forecasting based on VMD-FIG and parameter-optimized GRU [J]. *Acta Energiae Solaris Sinica*, 2021, 42(10): 237-242. DOI: [10.19912/j.0254-0096.tynxb.2019-1083](https://doi.org/10.19912/j.0254-0096.tynxb.2019-1083).
- [12] 吴迪, 刘怀西, 苗得胜. 尾流算法与风向变化对海上风机排布影响研究 [J]. *南方能源建设*, 2019, 6(2): 54-58. DOI: [10.16516/j.gedi.issn2095-8676.2019.02.010](https://doi.org/10.16516/j.gedi.issn2095-8676.2019.02.010).
WU D, LIU H X, MIAO D S. Research on offshore wind farm units layout considering the algorithm of wake model and the change of wind direction [J]. *Southern Energy Construction*, 2019, 6(2): 54-58. DOI: [10.16516/j.gedi.issn2095-8676.2019.02.010](https://doi.org/10.16516/j.gedi.issn2095-8676.2019.02.010).
- [13] DRAGOMIRETSKIY K, ZOSKO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544. DOI: [10.1109/tsp.2013.2288675](https://doi.org/10.1109/tsp.2013.2288675).
- [14] RICHMAN J S, LAKE D E, MOORMAN J R. Sample entropy [J]. *Methods in Enzymology*, 2004, 384: 172-184. DOI: [10.1016/S0076-6879\(04\)84011-4](https://doi.org/10.1016/S0076-6879(04)84011-4).
- [15] ZHANG Y G, PAN G F. A hybrid prediction model for forecasting wind energy resources [J]. *Environmental Science and Pollution Research*, 2020, 27(16): 19428-19446. DOI: [10.1007/s11356-020-08452-6](https://doi.org/10.1007/s11356-020-08452-6).
- [16] GRAVES A. Long short-term memory [M]//GRAVES A. Supervised Sequence Labelling with Recurrent Neural Networks. Berlin, Heidelberg: Springer, 2012: 37-45. DOI: [10.1007/978-3-642-24797-2_4](https://doi.org/10.1007/978-3-642-24797-2_4).
- [17] 国家市场监督管理总局, 国家标准化管理委员会. 风电场气象观测资料审核、插补与订正技术规范: GB/T 37523—2019 [S]. 北京: 中国标准出版社, 2019.
State Administration for Market Regulation, Standardization Administration. Specification for data inspection and correction of wind power plant meteorological observation: GB/T 37523—2019 [S]. Beijing: Standards Press of China, 2019.

作者简介:



李秀昊 (第一作者, 通信作者)

1994-, 女, 广东韶关人, 工程师, 硕士, 主要从事人工智能技术在新能源领域的研究与应用工作(e-mail)lixiuhao@mywind.com.cn。

李秀昊

刘怀西

1990-, 男, 江苏连云港人, 工程师, 硕士, 主要从事风电场规划设计的相关工作(e-mail)liuhuaixi@mywind.com.cn。

张智勇

1995-, 男, 广东韶关人, 学士, 工程师, 主要从事配网自动化及分布式新能源相关工作(e-mail)1578446332@qq.com。

张敏

1990-, 男, 山西晋中人, 工程师, 硕士, 主要从事风资源技术相关的研究工作(e-mail)zhangmin@mywind.com.cn。

吴迪

1983-, 女, 吉林长春人, 工程师, 硕士, 主要从事风资源技术相关的研究工作(e-mail)wudi02@mywind.com.cn。

苗得胜

1989-, 男, 河南济源人, 工程师, 硕士, 主要从事风资源评估研究工作(e-mail)miaodesheng@mywind.com.cn。

(编辑 李辉)

广 告

神泉二海上风电场项目	封一
神泉二海上风电场项目当年开工、当年全容量并网	封二
海上风能, 谱写新篇——大连理工大学海上风电团队	p160
《南方能源建设》第三届编委会	封三
中国能源建设集团广东省电力设计研究院有限公司	封四