

# 基于注意力机制的VMD-CNN-LSTM短期风电功率预测

曹洪宇<sup>1,2\*</sup>, 邵星<sup>2</sup>, 王翠香<sup>1</sup>, 皋军<sup>1</sup>

<sup>1</sup>盐城工学院信息工程学院, 江苏 盐城

<sup>2</sup>盐城工学院机械工程学院, 江苏 盐城

收稿日期: 2023年12月15日; 录用日期: 2024年1月5日; 发布日期: 2024年2月29日

## 摘要

针对传统物理机理驱动预测风电功率的方法存在预测结果精确度欠佳、泛化能力弱的问题, 提出一种基于注意力机制的VMD-CNN-LSTM短期风电功率预测方案。首先采用变分模态分解算法将风电功率序列分解并进行重构。然后利用注意力机制对每个特征分配不同权重。最后通过CNN-LSTM组合网络对每个分量进行训练和预测并重构后输出预测结果。实验结果表明, 基于注意力机制的VMD-CNN-LSTM模型在风电功率预测方面具有更高的预测精确度和泛化性。

## 关键词

风电功率预测, 注意力机制, 变分模态分解, 长短期记忆, 卷积神经网络

# VMD-CNN-LSTM Short-Term Wind Power Prediction Based on Attention Mechanism

Hongyu Cao<sup>1,2\*</sup>, Xing Shao<sup>1</sup>, Cuixiang Wang<sup>1</sup>, Jun Gao<sup>1</sup>

<sup>1</sup>School of Information Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

<sup>2</sup>School of Mechanical Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

Received: Dec. 15<sup>th</sup>, 2023; accepted: Jan. 5<sup>th</sup>, 2024; published: Feb. 29<sup>th</sup>, 2024

## Abstract

Aiming at the problems of poor prediction accuracy and weak generalization ability of the traditional physical mechanism-driven wind power prediction method, a VMD-CNN-LSTM short-term wind power prediction scheme based on attention mechanism is proposed. First, the variational

\*通讯作者。

文章引用: 曹洪宇, 邵星, 王翠香, 皋军. 基于注意力机制的 VMD-CNN-LSTM 短期风电功率预测[J]. 运筹与模糊学, 2024, 14(1): 710-722. DOI: 10.12677/orf.2024.141067

mode decomposition algorithm is used to decompose and reconstruct the wind power sequence. Then use the attention mechanism to assign different weights to each feature. Finally, the CNN-LSTM combination network is used to train and predict each component and output the prediction result after reconstruction. The experimental results show that the VMD-CNN-LSTM model based on the attention mechanism has higher prediction accuracy and generalization in wind power prediction.

## Keywords

Wind Power Prediction, Attention Mechanism, Variational Mode Decomposition, Long-Short-Term Memory, Convolutional Neural Network

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着全球能源安全问题日益突出,以及气候转变等环境问题的加剧,风力发电技术逐渐受到了全球各国的关注[1]。中国能源局的资料表明,2022年上半年全国风能新增1294万千瓦。其中陆上风能新增装机1206万千瓦,海上风能新增装机27万千瓦。截止2022年6月底,风电装机3.42亿千瓦[2]。自然风力会随天气变化呈现不规律波动,导致发电功率不稳定。同时,风电在全国电网中的占比也具有非平稳性,这些不稳定因素都对电网的安全可靠运行带来挑战。因此,能否精确地预测风力发电的功率对电网的规划和安全运行具有重要意义。

目前,风电功率预测的典型方法有时间序列模型[3]、机器学习模型[4]、深度学习[5]和组合预测模型[6]等。文献[7]通过构建ARIMA模型计算历史风电序列特征以预测短期风电功率。但由于风电功率序列的非平稳性,其MAPE值仅为4.9%,效果并不理想;文献[8]采用改进的ARIMA模型,通过神经网络模型修正风电功率序列特征,减少了风电功率中的不平稳性特征的影响,提高了预测精确度;文献[9]采用极限学习机-LSTM组合模型训练,并通过加权灰色关联算法提取特征近似的历史数据,缩小了风电功率预测误差分布范围;文献[10]采用CNN-LSTM神经网络组合模型进行训练,利用主成分分析法(PCA)对原始气象特征降维,以实现风电功率的精确预测;文献[11]采用变分模态分解(VMD)、卷积长短期记忆网络(ConvLSTM)和误差分析构建的组合模型用于短期风电功率预测。结果表明,该模型相比单一模型,能更有效挖掘出风电功率序列特征,具备更好的预测性能。文献[12]通过引入基于注意力的门控循环单元(AGRU),提高了模型的预测精确度。该模型通过嵌入了GRU块的隐藏激活函数来关联不同预测步骤的任务,并设计一种注意力机制作为特征选择方法以识别关键输入变量。通过组合不同模型,合理运用各个模型的特点和优势,组合模型相比单一模型具备更好的稳定性,但其适用范围也存在一定限制[13]。

综上所述,目前常见的风电功率预测模型结构简单且易于应用,能够基本满足预测需求。但缺乏对数据波动性的考虑,相对于组合模型存在泛化性弱、抗干扰能力差、特征提取能力不足、预测精确度不佳等问题[14]。为此本文提出一种基于注意力机制的VMD-CNN-LSTM短期风电功率预测模型。首先利用变分模态分解(VMD)算法将风电功率序列分解成若干个分量,再采用注意力机制对历史气象特征和轴承变量分配不同权重,实现特征融合。之后,通过卷积神经网络(CNN)对带有权重特征的新数据进行其特征的深度挖掘。最后,将挖掘出的局部特征数据以时间序列格式输入长短期记忆网络(LSTM)训练。其

中, LSTM 对每个分量结合气象特征和轴承变量的关联性进行训练, 对输出结果重构并获得最终风电功率预测值。另外, 为了提升模型的整体性能, 使用 hyperopt 贝叶斯算法对整体模型的超参数迭代寻优[15]并输出最终模型。本文相对于传统风电功率组合模型有两点创新: 一是在数据预处理过程采用 VMD 算法, 对风电功率序列数据分解成若干个子分量, 对每个分量结合风电功率特征变量训练, 再对各个分量的预测结果重构, 解决了风电功率序列波动性大, 噪声强的问题。二是在 CNN-LSTM 组合模型中引入注意力机制, 对关键的特征分配强权重, 将复杂的特征简单化, 增强了 LSTM 的记忆能力。在 Elia 比利时电网公司提供的开源风电功率数据集上的实验结果表明, 本文提出的基于注意力机制的 VMD-CNN-LSTM 预测模型, 相比于其他模型, 具备更好的风电功率预测精确度和泛化性。

## 2. 模型构建原理

### 2.1. VMD 简介

风电功率序列信号具有非平稳性, 将其分解成多个子序列以降低功率序列的复杂程度。在一般情况下对于长序列的信号分解, EMD 算法的使用较为广泛。但该算法的本征模态函数分量数目不能人为控制, 且分解模态分量较大时, 易出现模态混叠情况导致预测精确度不高[16]。VMD 算法[17]作为一种新型信号分解技术, 弥补了 EMD 技术缺陷。因此本文使用 VMD 对风电功率数据进行分解。

假设原始信号  $f$  可分解为  $k$  个分量, 分解序列为具有不同中心频率的本征模态函数(Intrinsic Mode Function, IMF), 则约束的变分表达式如式(1)所示:

$$\min \left\{ \sum_{k=1}^k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} * u_k(t) \right) e^{-jw_k t} \right] \right\|_2^2 \right\} \quad (1)$$

式中:  $u_k$  为模态信号,  $\delta(t)$  为狄拉克函数,  $f$  为时间序列,  $k$  为模态数,  $w_k$  为第  $k$  个模态的中心频率。

利用 Lagrange 乘子  $\lambda$  将变分问题转换为非约束性问题, 得到变分约束模型的最优解。其中, 增广 Lagrange 表达式如式(2)所示:

$$L(\{U_K\}, \{W_K\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{jw_k t} \right\|_2^2 + \|f(t) - u_k(t)\|_2^2 + \left[ \lambda(t), f(t), f(t) - \sum_{k=1}^K u_k(t) \right] \quad (2)$$

式中:  $\alpha$  为二次惩罚因数,  $\lambda$  为拉格朗日乘子。使用交替乘法, 计算得到  $u_k$  和  $w_k$ 。

通过迭代更新后得到迭代分量  $\hat{u}_k^{n+1}$ 、迭代中心频率  $\hat{w}_k^{n+1}$ 、迭代 Lagrange 乘子  $\hat{\lambda}_k^{n+1}$  的表达式如下:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i^n(w) + \frac{\hat{u}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (3)$$

$$w_k^{n+1}(w) = \frac{\int_0^\infty w |\hat{u}_k^n(w)|^2 dw}{\int_0^\infty |\hat{u}_k^n(w)|^2 dw} \quad (4)$$

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \gamma \left( \hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w) \right) \quad (5)$$

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon, n < N \quad (6)$$

式中:  $\varepsilon$  为迭代收敛阈值,  $N$  为最大迭代次数。

## 2.2. 基于中心频率确定分量个数

在对功率序列使用 VMD 算法进行分解时,  $k$  的取值合适与否至关重要。当取值较小时, 易造成欠分解; 当  $k$  值较大时, 会出现模态混叠或噪声增加的情况。这两种情况都会影响到模型对风电功率序列预测的精确度。本文分别取  $k$  值为 3, 4, 5, 6, 7, 并标记对应分量的中心频率。最终当第  $k$  次出现中心频率相近的  $k$  值时, 即确定  $k-1$  为分解模态的数目, 以此参数分解风电功率序列。

## 2.3. 加入注意力机制的预测模型

CNN-LSTM 模型本身已具备强大的性能, 但当输入的特征信息比较多时, 模型的复杂度会增加, 导致 LSTM 网络对于长序列输入特征信息的记忆能力不高。虽然 CNN 局部连接、权值共享等优化操作能够一定程度上降低模型的复杂度, 但仍有进一步提升的空间。综合考虑以上问题, 引入了注意力机制, 以进一步提升 CNN-LSTM 模型的预测精确度。首先对每个 IMF 分量和收集的相关气象特征以及轴承变量使用 MinMaxScaler 算法归一化[18], 并分别在 CNN-LSTM 网络建模, 再对输入特征变量分配自适应权重系数, 从而改变输入特征变量对输出结果的贡献率, 以缓解模型复杂度和表达能力之间的矛盾, 最终获得风电功率序列与特征之间的相关性信息, 进一步提高 CNN-LSTM 组合模型的预测精确度。

## 3. 基于注意力机制的 VMD-CNN-LSTM 风电功率预测

### 3.1. 预测模型结构

本文研究的目标为设计一种基于注意力机制的组合预测模型, 用以实现对风电功率序列高精度预测。首先通过 VMD 算法对风电功率序列进行分解, 得到若干个本征模态函数分量。之后凭借 CNN 网络深入挖掘输入特征变量和风电功率序列分量之间的相关性。引入注意力机制对不同特征划分权重系数, 以减少模型的复杂度。利用 LSTM 模块解决功率序列与特征之间的长依赖问题, 得到风电功率序列的变化规律, 输出各分量的预测结果。最后对输出数据进行重构, 得到最终预测结果。

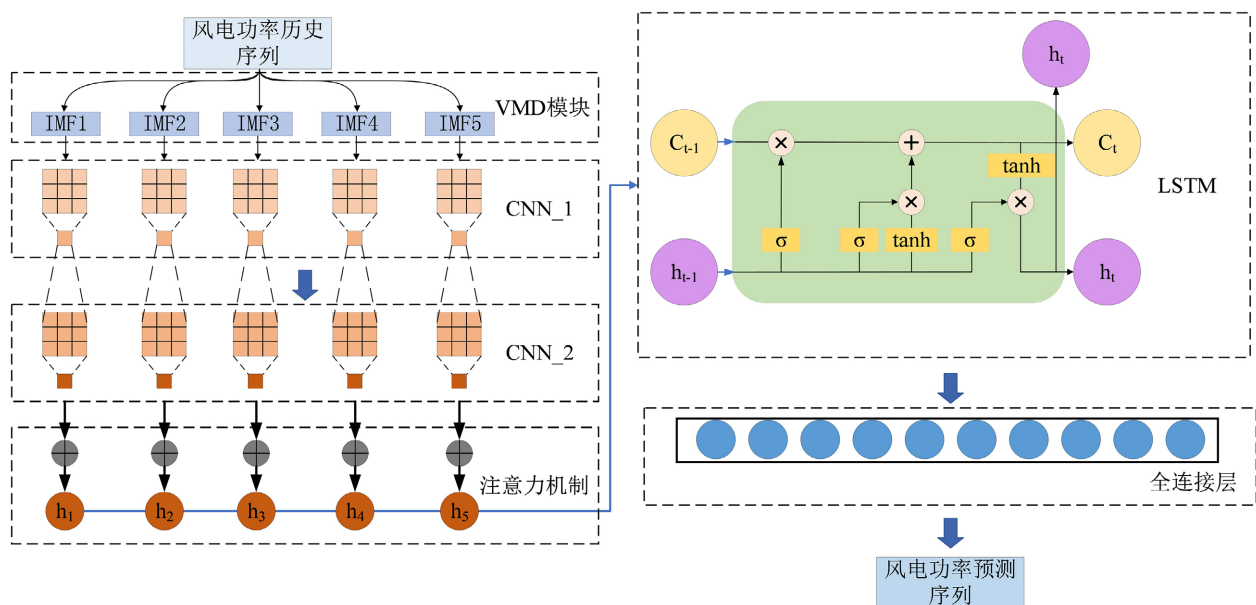


Figure 1. The structure of VMD-CNN-LSTM model based on attention mechanism

图 1. 基于注意力机制的 VMD-CNN-LSTM 模型结构

模型整体结构如图 1 所示, 包括变分模态分解模块、卷积神经网络模块、注意力机制模块和长短期记忆模块。变分模态分解模块中 IMF 分量的数量  $k$  取值为 5,  $\alpha$  设置为 7000,  $\text{tol}$  精确度设置为 0.0000007,  $\text{init}$  初始化  $W$  值为 1, 以避免风电功率序列在迭代过程中端到端效应以及虚假分量问题, 减缓模态混叠现象。卷积神经网络模块包括两个不同卷积核大小的卷积层和一个最大池化层。这样设置可以让不同宽度的卷积核结合下采样操作, 利于挖掘风电功率序列的潜在特征, 并抑制序列的高频噪声。注意力机制模块采用单通道注意力模块, 结合  $\text{softmax}$  归一化激活函数计算风电功率特征权重, 对关键特征重新赋予较大权重。长短期记忆模块设置为两层, 隐藏节点数分别为 100, 200。为了避免过拟合, 在 LSTM 模块的最后一层设置了  $\text{dropout}$  层, 让某部分神经元停止工作, 减少神经元之间复杂的共适应关系, 缓解过拟合现象, 提高组合模型的泛化性。

### 3.2. 评价指标

采用均方误差 MSE, 均方根误差 RMSE, 平均绝对误差 MAE 和平均绝对百分比误差 MAPE [19] 作为预测模型的评价指标, 各个误差函数的表达式分别如下:

$$\begin{aligned}
 E_{mse} &= \frac{1}{m} \sum_{i=1}^m (\tilde{y}_i - y_i)^2 \\
 E_{rmse} &= \sqrt{\frac{1}{m} \sum_{i=1}^m (\tilde{y}_i - y_i)^2} \\
 E_{mae} &= \frac{1}{m} \sum_{i=1}^m |\tilde{y}_i - y_i| \\
 E_{mape} &= \frac{100\%}{m} \sum_{i=1}^m \left| \frac{\tilde{y}_i - y_i}{y_i} \right|
 \end{aligned} \tag{7}$$

式中:  $m$  为样本的数量;  $y_i$  为样本  $i$  风电功率的实际值;  $\tilde{y}_i$  为样本  $i$  风电功率的预测值。在风电功率预测中, 如果上述四种指标的数值越小, 表示预测值与实际风电功率值的差异越小, 预测精确度越高, 反之, 则越低。

## 4. 算例分析

### 4.1. 数据集

本文使用比利时电力公司(Elia Wind grid)观测站站点提供的公开数据集。原始数据集中的特征数据包括了风电功率、风速、风向和环境温度等 14 个维度数据。实验数据集取自波罗的海(Baltic Sea)的海上风电场。

总计 23,520 个小时的数据样本。将训练集、验证集和测试集的样本数量按照 6:1:3 的比例进行划分。其中, 训练集有 14,112 个样本, 验证集有 2352 个样本, 测试集有 7056 个样本。

### 4.2. 数据处理

Baltic 站点风电功率的数据集样本足够多。因此, 将有缺失的数据直接整行删除, 对剩余数据进行归一化处理, 对非数值数据进行 one-hot 编码。最后通过因素相关性分析以及 VMD 算法将功率序列分解为若干个分量。

#### 4.2.1. 因素相关性分析

本文利用斯皮尔曼相关系数[20] (Spearman Correlation Coefficient, SCC)对特征向量和目标向量进行相关程度分析。和皮尔逊相关系数(Spearman Correlation Coefficient, PCC)相比, SCC 无需对数据进行正

态性检验，可以更好地显示二者的关联程度。

SCC 算法所使用的数据是“秩”，即根据向量数的大小排列等级而不是数值本身，其具体表达式为：

$$\rho_s = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (8)$$

式中： $N$  为样本数； $X_i$  为特征因素等级数； $\bar{X}$  和  $\bar{Y}$  分别为某气象和轴承因素与风电功率的平均等级数。

$\rho_s$  取值范围在-1 到 1 之间。如果  $\rho_s > 0$ ，则表明二者呈正相关关系，否则呈现负相关。 $\rho_s$  的绝对值越接近 1，则说明二者相互关联的程度就越高，反之越低。比利时电力公司风电场的实测数据的特征包括环境温度、轴承轴温度、叶片 3 桨距角、齿轮箱轴承温度、齿轮箱油温、发电机转速、发电机绕组 2 温度、轮毂温度、主箱温度、无功功率、涡轮机状态、风向和风速。这些特征与风电功率之间的 SCC 如表 1 所示。

从表 1 可知，发电机转速、风速、无功功率与风电功率的 SCC 分别为 0.984、0.983 和 0.981，存在较强关联性；齿轮箱轴承温度、发电机绕组 2 温度、齿轮箱油温和轴承轴温度与风电功率呈现弱相关关系，而环境温度、叶片 3 桨距角、轮毂温度、逐项温度、涡轮机状态和风向的 SCC 值很低，表明上述特征几乎与风电功率没有关联，所以将发电机转速、风速、无功功率、齿轮箱轴承温度、发电机绕组 2 温度、齿轮箱油温和轴承轴温度等 7 个相关性强的特征因素作为输入特征。

**Table 1.** Correlation coefficient between wind power and characteristic factors  
**表 1.** 风电功率与特征因素之间的相关系数

因素	相关系数
环境温度	0.027
轴承轴温度	0.735
叶片 3 桨距角	-0.437
齿轮箱轴承温度	0.924
齿轮箱油温	0.858
发电机转速	0.984
发电机绕组 2 温度	0.920
轮毂温度	0.348
主箱温度	0.133
无功功率	0.981
风向	0.283
风速	0.983


#### 4.2.2. 变分模态分解分析

为获取更加可信的数据集，并充分发掘风电功率序列和特征因素之间的潜在规律。采用 VMD 算法把风电功率序列划分成了若干个分量。该算法通过中心频率法来确定模态数量  $k$ 。一般情况下， $k$  取值范围为 3~7。据表 2 可得， $k$  从 5 到 6 的值相似，可得， $k$  选 5。并结合模态混叠情况，模块参数： $\alpha$  为 7000， $\text{tol}$  精确度为  $1e-7$ ， $\text{init}$  初始化  $W$  值为 1，使之均匀分布产生随机数。 $k$  值为 5，将风电功率序列分解为 5 个模态分量。

**Table 2.** Center frequency for different number of modes  $k$   
**表 2.**  $k$  个模态分量的中心频率

$k$	U1	U2	U3	U4	U5	U6	U7
3	0.000081	0.008366	0.027493				
4	0.000076	0.008006	0.022158	0.045790			
5	0.000076	0.007969	0.021707	0.043946	0.0939320		
6	0.000074	0.007836	0.020068	0.039356	0.0720915	0.410210	
7	0.000073	0.007727	0.018643	0.036453	0.0630600	0.097939	0.410332

从图 2 中各个分量的频谱图和图 3 的中心模态分布图可知, IMF1 原始频谱呈现很强的不稳定性, 当进行一级分解时, 不稳定性开始趋于稳定, 当进行 IMF4 到 IMF5 分解时, 频谱呈现稳定状态, 说明此时风电功率序列分解比较理想。



**Figure 2.** IMF component spectrogram  
**图 2.** IMF 分量频谱图

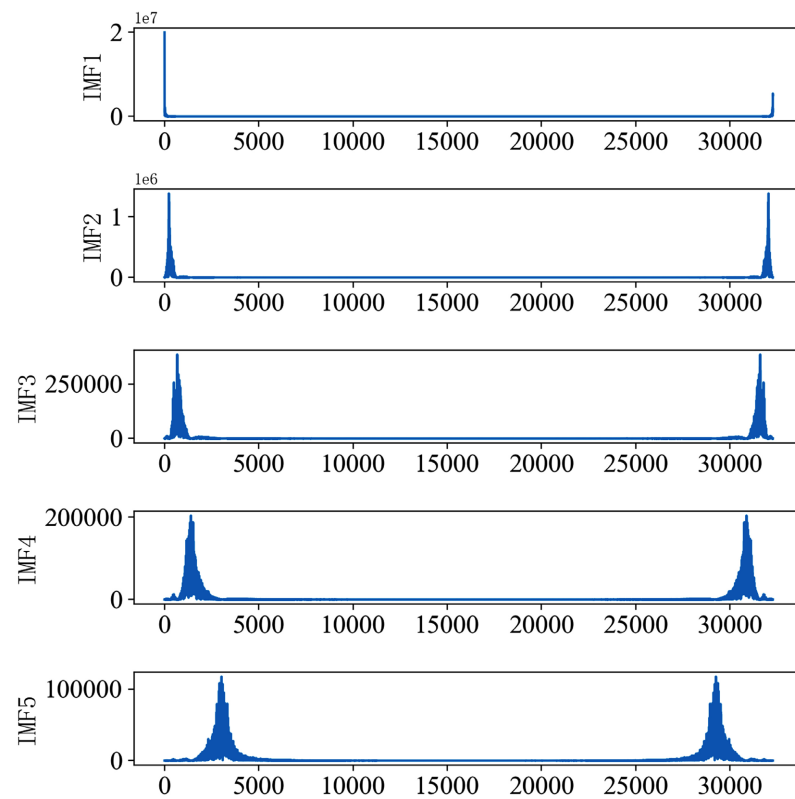


Figure 3. IMF Central Mode Distribution Diagram  
图 3. IMF 中心模态分布图

### 4.3. 预测结果分析

各个模型主要超参数见表 3。

Table 3. The main hyperparameters of the model

表 3. 模型主要超参数

模型	主要参数	说明
ARIMA	$p = 8$ $d = 1$ $q = 2$	自相关阶数 差分次数 移动平均阶数
SVR	Kernel Function $C = 1$	Radial Basis Function RBF 惩罚因子
LSTM	units1 = 100 units2 = 200	第一层神经元数量 第二层神经元数量
CNN	kernel_size = 5, 3 activation = 'relu' pool_size = 2	卷积窗口长度 激活函数 最大池化窗口尺寸
VMD	alpha = 7000 $k = 5$ tol = $1e-7$	带宽限制 分解模态个数 误差常量
AM	activation = "softmax"	激活函数



为检验本文所给出预测模型的有效性和可行性,对本文模型与 ARIMA 模型、SVR 模型、LSTM 模型、CNN 模型、VMD-LSTM 模型、VMD-CNN 模型、VMD-AM-LSTM 模型、CNN-LSTM 模型、CNN-AM-LSTM 模型、VMD-CNN-LSTM 模型的预测效果进行比较。由表 4 可以看出,本文所提组合模型相较于 ARIMA、SVR、LSTM、CNN 单一预测模型, RMSE 分别降低了 80.1%、72.07%、56%、59.78%; MAE 分别降低了 84.82%、38.71%、59.85%、66.56%; MAPE 分别降低了 30.99%、32.11%、31.49%、18.3%。相较于 VMD-CNN、VMD-LSTM、VMD-AM-LSTM、CNN-LSTM、CNN-AM-LSTM、VMD-CNN-LSTM 组合模型, RMSE 分别降低了 35.31%、27.17%、0.76%、63.06%、71.47%、41.02%; MAE 分别降低了 44.82%、38.90%、2.23%、68.92%、76.01%、49.62%; MAPE 分别降低了 2.94%、2.82%、44.22%、22.1%、15.1%、6.32%。其中,与文献[21]中 CNN-LSTM-lightGBM 组合算法模型横向量化比较, RMSE、MAE 和 MAPE 指标分别将降低了 15.8%、35.2%、13.4%。与文献[22]中 TPE-LSTM 智能优化算法横向量化比较, RMSE 指标降低了 43.2%, MAPE 指标略有差距,但本文所提出的组合模型在其他关键性能指标具有显著优势。

**Table 4.** Comparison of wind power prediction results of various models  
**表 4.** 不同模型风电功率预测结果对比

模型	评价指标		
	$E_{RMSE}/kW$	$E_{MAE}/kW$	$E_{MAPE}/kW$
ARIMA	5.4373	4.8087	6.926
SVR	3.6805	1.1910	5.721
LSTM	2.3361	1.8182	5.586
CNN	2.5554	2.1832	4.684
VMD-CNN	1.5887	1.3229	3.943
VMD-LSTM	1.4112	1.1947	3.938
VMD-AM-LSTM	1.0357	0.7467	6.861
CNN-LSTM	2.7824	2.3491	4.913
CNN-AM-LSTM	3.6028	3.0453	4.510
VMD-CNN-LSTM	1.7425	1.4490	4.085
CNN-LSTM-lightGBM	1.222	1.126	4.420
TPE-LSTM	1.809	-	2.678
VMD-AM-CNN-LSTM	1.0278	0.7300	3.827

从图 4 可以明显看出,在风电功率变化较大的极点处,基于注意力机制的 VMD-CNN-LSTM 网络模型预测值更接近实际值,说明本文提出的网络模型具有在极端情况下更好地预测风电功率的能力。

多组实验结果分析发现,同一模型对同源不同规模的采样点具有更优的预测效果,通过使用本文提出的基于注意力机制的 VMD-CNN-LSTM 模型对 1000 个采样点间隔 100 个单位进行预测,对得到的 10 个不同的平均绝对百分比误差值进行分析。从图 5 误差的结果可以很明显的看出,在本文提出的模型中,同一模型对同源的不同规模的采样点的 MAPE 值在 0.22%~0.31%之间,比同时预测 9685 个采样点 MAPE 值降低了 42%~18.4%。

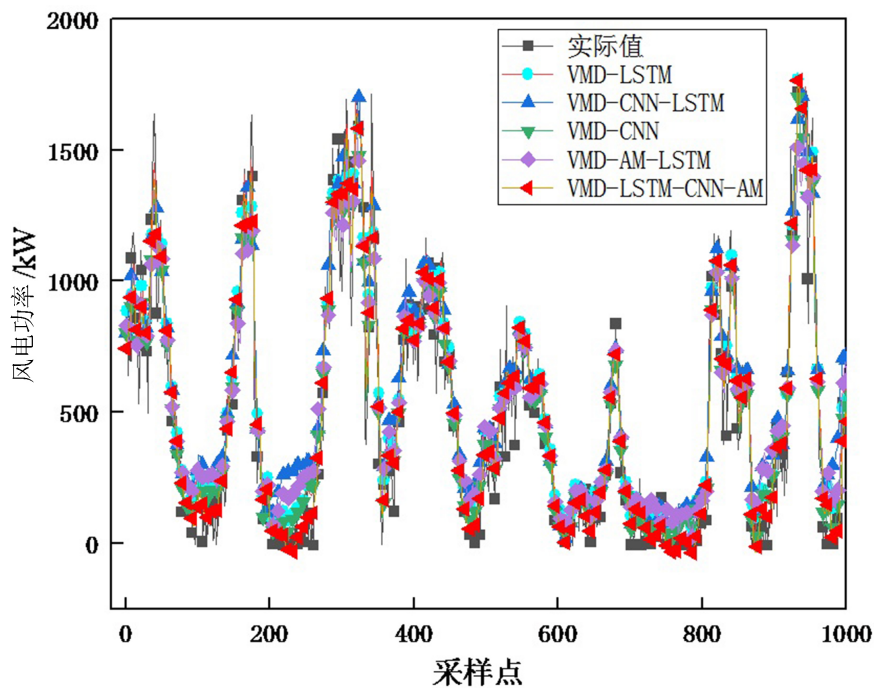


Figure 4. Predictions from different model

图 4. 不同组合模型的预测结果

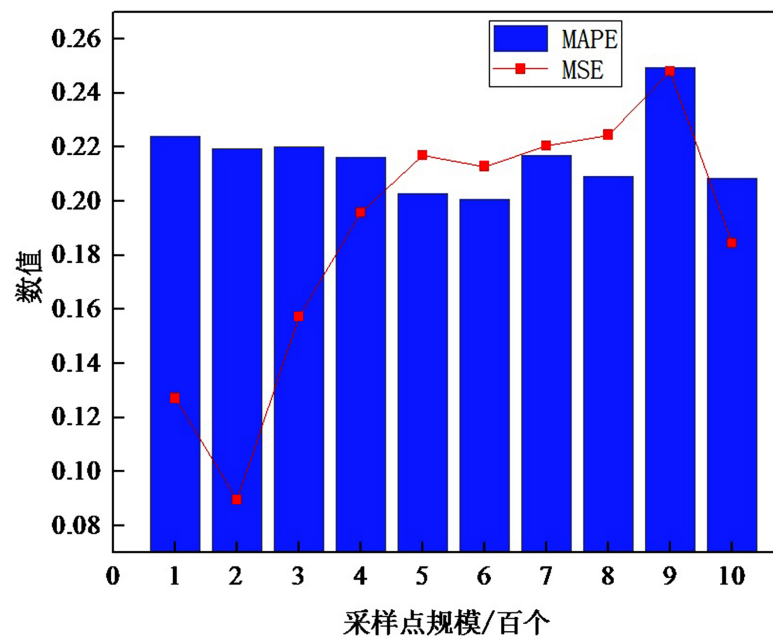


Figure 5. MAPE values of the same model homology at different scales

图 5. 同一模型同源不同规模的 MAPE 值

为检验文中所给出模型的泛化性，分别选取夏季和冬季作为实验对象，如图 6 和图 7 所示。从图中可以看出，在夏季，风电功率变化较小，其 MAPE 值是 0.2942。在冬季，风电功率变化较大，其 MAPE 值是 0.2909。由预测结果可得，在夏季和冬季两种极端条件下，本文给出的模型的误差均小于传统神经网络预测方法。说明本文组合模型具备更强的泛化性能。




Figure 6. Summer sampling point  
图 6. 夏季采样点




Figure 7. Winter sampling point  
图 7. 冬季采样点

### 5. 结论

本文旨在解决当前传统物理机理驱动预测风电功率的方法中精确度不高和泛化能力弱的问题，提出了一种基于注意力机制的 VMD-CNN-LSTM 短期风电功率预测方法。

首先通过 VMD 变分模态分解实现对风电功率时间序列的固有模态分量的有效分解，克服了复杂且非线性强的时间序列问题。其次，引入 CNN-LSTM 组合网络模型提高了特征提取能力，解决了长依赖问

题，并在组合模型中加入注意力机制模块进一步提高了预测精确度。通过斯皮尔曼相关系数特征分析法对气象和轴承数据的深入分析，对原始轴承数据进行了等级划分，降低了网络模型复杂度，提高了预测精确度。技术创新点在于综合运用 VMD、CNN、LSTM 和注意力机制，从而构建了一种在风电功率预测中具有显著优势的综合模型。研究表明，本文方法在提高预测精确度和泛化性能方面较传统方法更为优越，与组合算法 CNN-LSTM-lightGBM 以及 TPE-LSTM 模型横向相比，关键性能较为突出，说明了本文组合模型的先进性。然而，本文仍存在不足之处，包括缺少多个数据集进行多工况分析，未来研究方向可集中在优化模型参数的基础上，增加数据集多工况的对比，进一步提高并验证模型预测精确度和泛化能力。

## 实验数据

该文所有实验代码与结果可在

<https://github.com/chyaou/VMD-CNN-LSTM-AM-wind-power-forecast.git> 获取。

## 基金项目

国家自然科学基金(62076215); 教育部新一代信息技术创新项目(2020ITA02057); 盐城工学院研究生科研与实践创新计划项目(SJ CX22\_XZ035、SJ CX22\_XY061)。

## 参考文献

- [1] Chen, Y. and Lin, H. (2022) Overview of the Development of Offshore Wind Power Generation in China. *Sustainable Energy Technologies and Assessments*, **53**, Article ID: 102766. <https://doi.org/10.1016/j.seta.2022.102766>
- [2] 姚金楠. 国家能源局: 上半年新增发电装机八成为可再生能源[N]. 中国能源报, 2022-08-08(001).
- [3] 唐新姿, 顾能伟, 黄轩晴, 等. 风电功率短期预测技术研究进展[J]. 机械工程学报, 2022, 58(12): 213-236.
- [4] Demolli, H., Dokuz, A.S., Ecemis, A. and Gokcek, M. (2019) Wind Power Forecasting Based on Daily Wind Speed Data Using Machine Learning Algorithms. *Energy Conversion and Management*, **198**, Article ID: 111823. <https://doi.org/10.1016/j.enconman.2019.111823>
- [5] Hong, Y.Y. and Rioflorido, C.L.P.P. (2019) A Hybrid Deep Learning-Based Neural Network for 24-H Ahead Wind Power Forecasting. *Applied Energy*, **250**, 530-539. <https://doi.org/10.1016/j.apenergy.2019.05.044>
- [6] Qian, Z., Pei, Y., Zareipour, H. and Chen, N.Y. (2019) A Review and Discussion of Decomposition-Based Hybrid Models for Wind Energy Forecasting Applications. *Applied Energy*, **235**, 939-953. <https://doi.org/10.1016/j.apenergy.2018.10.080>
- [7] Yatiyana, E., Rajakaruna, S. and Ghosh, A. (2017) Wind Speed and Direction Forecasting for Wind Power Generation Using ARIMA Model. 2017 *Australasian Universities Power Engineering Conference (AUPEC)*, Melbourne, 19-22 November 2017, 1-6. <https://doi.org/10.1109/AUPEC.2017.8282494>
- [8] Singh, P.K., Singh, N. and Negi, R. (2019) Wind Power Forecasting Using Hybrid ARIMA-ANN Technique. In: Hu, Y.C., Tiwari, S., Mishra, K. and Trivedi, M., Eds., *Ambient Communications and Computer Systems*, Springer, Singapore, 209-220. [https://doi.org/10.1007/978-981-13-5934-7\\_19](https://doi.org/10.1007/978-981-13-5934-7_19)
- [9] 仲悟之, 李崇钢, 崔杨, 等. 考虑历史相似性加权的超短期风电功率组合预测[J]. 太阳能学报, 2022, 43(6): 160-168.
- [10] 栗然, 马涛, 张潇, 等. 基于卷积长短期记忆神经网络的短期风功率预测[J]. 太阳能学报, 2021, 42(6): 304-311.
- [11] Sun, Z. and Zhao, M. (2020) Short-Term Wind Power Forecasting Based on VMD Decomposition, ConvLSTM Networks and Error Analysis. *IEEE Access*, **8**, 134422-134434. <https://doi.org/10.1109/ACCESS.2020.3011060>
- [12] Niu, Z., Yu, Z., Tang, W., et al. (2020) Wind Power Forecasting Using Attention-Based Gated Recurrent Unit Network. *Energy*, **196**, Article ID: 117081. <https://doi.org/10.1016/j.energy.2020.117081>
- [13] 姜贵敏, 陈志军, 李笑竹, 等. 基于 EEMD-ACS-LSSVM 的短期风电功率预测[J]. 太阳能学报, 2020, 41(5): 77-84.
- [14] 叶家豪, 魏霞, 黄德启, 等. 基于灰色关联分析的 BSO-ELM-AdaBoost 风电功率短期预测[J]. 太阳能学报, 2022, 43(3): 426-432.

- 
- [15] Díaz-Vicod, D., Torres-Barrán, A., Omari, A. and Dorronsoro, J.R. (2017) Deep Neural Networks for Wind and Solar Energy Prediction. *Neural Processing Letters*, **46**, 829-844. <https://doi.org/10.1007/s11063-017-9613-7>
- [16] 王福忠, 王帅峰, 张丽. 基于 VMD-LSTM 与误差补偿的光伏发电超短期功率预测[J]. 太阳能学报, 2022, 43(8): 96-103.
- [17] 盛四清, 金航, 刘长荣. 基于 VMD-WSGRU 的风电场发电功率中短期及短期预测[J]. 电网技术, 2022, 46(3): 897-904.
- [18] Wang, K., Qi, X., Liu, H. and Song, J.K. (2018) Deep Belief Network Based K-Means Cluster Approach for Short-Term Wind Power Forecasting. *Energy*, **165**, 840-852. <https://doi.org/10.1016/j.energy.2018.09.118>
- [19] Santhosh, M., Venkaiah, C. and Vinod Kumar, D.M. (2020) Current Advances and Approaches in Wind Speed and Wind Power Forecasting for Improved Renewable Energy Integration: A Review. *Engineering Reports*, **2**, e12178. <https://doi.org/10.1002/eng2.12178>
- [20] Rubanenko, O., Miroshnyk, O., Shevchenko, S., et al. (2020) Distribution of Wind Power Generation Dependently of Meteorological Factors. 2020 *IEEE KhPI Week on Advanced Technology (KhPIWeek)*, Kharkiv, 5-10 October 2020, 472-477. <https://doi.org/10.1109/KhPIWeek51551.2020.9250114>
- [21] 王愈轩, 刘尔佳, 黄永章. 基于 CNN-LSTM-LightGBM 组合的超短期风电功率预测方法[J]. 科学技术与工程, 2022, 22(36): 16067-16074.
- [22] 查雯婷, 闫利成, 陈波, 等. 基于 TPE-LSTM 的区域超短期风电功率预测[J]. 计算机应用与软件, 2022, 39(11): 25-30, 111.