

## 二次分解组合 LSTM 的短期风电功率预测模型<sup>\*</sup>

杨生鹏<sup>1</sup> 文 中<sup>1</sup> 丁 剑<sup>2</sup> 张开伟<sup>1</sup> 张业伟<sup>1</sup> 倪 志<sup>1</sup>

(1. 三峡大学电气与新能源学院 宜昌 443002; 2. 上海勘测设计研究院有限公司 上海 200434)

**摘 要:**随着风电在电力系统中的占比逐步提高,风电功率的精确预测对电力系统的安全稳定运行具有重要意义。然而,风电的随机性和间歇性极大地影响其功率的精确预测。为此,提出二次分解组合长短期记忆(LSTM)的短期风电功率预测模型。首先,采用经验模态分解(EMD)技术将原始风电序列分解为若干固有模态分量;再采用样本熵(SE)技术将各分量重组为高、中、低频3个序列,针对高频模态混叠再次采用麻雀搜索算法-变分模态分解(SSA-VMD)二次分解技术;最后,采用SSA算法对LSTM的参数进行寻优并完成风电功率预测。以湖北省某风电场对所提模型进行验证,并与其他模型进行对比。结果表明,所提模型的平均绝对误差(MAE)为5.79 kW,均方根误差(RMSE)为5.64 kW,平均百分比误差(MAPE)为17.38%,具有更好的预测精度。

**关键词:**风电功率预测;经验模态分解;变分模态分解;麻雀搜索算法;长短期记忆

**中图分类号:** TN2      **文献标识码:** A      **国家标准学科分类代码:** 520.604

## Short-term wind power prediction model for quadratic decomposition combined LSTM

Yang Shengpeng<sup>1</sup> Wen Zhong<sup>1</sup> Ding Jian<sup>2</sup> Zhang Kaiwei<sup>1</sup> Zhang Yewei<sup>1</sup> Ni Zhi<sup>1</sup>

(1. School of Electrical and New Energy, China Three Gorges University, Yichang 443002, China;

2. Shanghai Survey, Design and Research Institution, Shanghai 200434, China)

**Abstract:** With the gradual increase of the proportion of wind power in the power system, the accurate prediction of wind power is of great significance to the safe and stable operation of the power system. However, the random and intermittent nature of wind power greatly affects the accurate prediction of its power. Therefore, this paper proposes a quadratic decomposition combination LSTM short-term wind power prediction model. Firstly, the EMD technique is used to decompose the original wind power series into several intrinsic mode components. Then, SE technique is used to recombine the components into three sequences: High, middle and low frequency. SSA-VMD technique is used for high frequency mode aliasing. Finally, SSA algorithm is used to optimize the parameters of LSTM and wind power prediction is completed. A wind farm in Hubei Province is used to verify the proposed model and compare with other models. The results show that the MAE, RMSE and MAPE of the proposed model are 5.79, 5.64 kW and 17.38%, respectively.

**Keywords:** wind power prediction; empirical mode decomposition; variational mode decomposition; sparrow search algorithm; long short term memory

### 0 引 言

随着石油等传统能源短缺问题的日益凸显,发展可再生能源已成为全球共识<sup>[1]</sup>。风能作为一种新型的可再生能源,利用风力发电已成为全球最成熟的技术之一<sup>[2-3]</sup>。但风力发电存在着不确定性和间歇性问题,给电力系统的

安全稳定运行带来了极大挑战。实际工程表明<sup>[4-5]</sup>,实现短期风电功率的精准预测可有效应对这一挑战。

从现有研究来看,风电功率的预测方法可归纳为物理方法<sup>[6-7]</sup>、统计方法<sup>[8-10]</sup>、浅层机器学习<sup>[11]</sup>和深度学习<sup>[12-14]</sup>4类。其中,物理方法<sup>[1,7]</sup>通过综合考虑风速、风向、温度、风电场结构等因素,来解析风电复杂的动态过程,进而实

收稿日期:2023-08-01

<sup>\*</sup> 基金项目:国家自然科学基金(52107108)项目资助

现风电功率的预测。但该方法需要物理建模,消耗的计算资源较大。常见的统计方法包括时间序列法<sup>[8]</sup>、卡尔曼滤波法<sup>[9]</sup>、回归分析法<sup>[10]</sup>等。该类方法通过分析历史数据可较为精确地输出未来的风电功率,但对于复杂地形和大型风电场景下预测的准确性存在一定局限性。在浅层机器学习方法中,文献[11]将支持向量机(support vector machines, SVM)和经验模态分解(empirical mode decomposition, EMD)相结合,进行风电功率的预测。该方法可有效减少欠冲击电数,改善风电功率预测的精确性,但方法的计算模型较为简单,致使其无法准确捕捉更深层次、更通用的时间信息,如长期趋势和周期性等。

为准确捕捉更深层次、更通用的时间信息,国内外学者开始尝试采用深度学习算法进行风电功率的预测。深度学习的算法包括深度神经网络(deep neural network, DNN)、深度置信网络(deep belief network, DBN)、卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)、长短期记忆网络(long and short time memory, LSTM)。文献[12]采用DNN进行风电功率预测,相较于以上3种预测方法,预测精度得到了提高,但缺少对风电功率数据的预处理,其内部的决策难以解释和理解。文献[13]引入了DBN算法,实现了对风电功率数据的分层处理,使得预测准确性进一步提高,但其需要大量的风电功率数据进行训练,且训练过程复杂。文献[14]采用CNN处理风电功率数据,相较于DBN,其参数量大大减少,提高了训练速度,但对于波动性较大的数据,预测的准确性会有所下降。文献[15]的RNN算法加入递归结构捕捉到更深层次、更通用的时间序列,在预测任务中表现的更出色,但存在的梯度爆炸问题限制了其在处理长序列时的能力。近年来,LSTM模型被指出并专门用于时间序列数据的建模,相较于上述的神经网络,LSTM引入了记忆单元、输入门、输出门和遗忘门等机制,解决了梯度爆炸问题,能够有效地捕捉和记忆长期依赖关系,但是单一的LSTM面对一些不规则或者长度差异的时间序列时,预测结果失准。

在上述研究的基础上,将分解方法与LSTM模型结合成为风电功率预测新的研究热点。文献[16]采用小波分解(wavelet decomposition, WD)对原始风电功率数据进行预处理,构建了不同信号的分组,有效提高了预测精度。文献[17]首先采用EMD将原始风电功率时间序列分解为多个特征模态函数,并重构为3个尺度子序列的预测模型,但不同的模态函数之间存在相互混叠的问题,影响分解的可靠性。文献[18]采用VMD-LSTM模型对风电功率进行短期预测,相比于上面两种分解方法具有更高的预测精度。

为进一步提高风电功率的预测精度,学者们提出了二次分解技术组合深度学习的方法。二次分解技术是在一次分解的基础上选取出平稳或不平稳的部分再次进行分解,降低信号的非线性和不平稳性,从预处理角度进一步

提高预测精度。文献[19]采用EMD和WD相结合的模型进行短期风电功率预测,结果表明其预测准确度比一次分解高。文献[20]采用VMD分解技术将原始信号分解成不用中心频率的内模态分量和一个残差模块,并采用WD对含高频噪声的分量进行去噪,取得了较好的预测结果。在风电功率预测方面,当前二次分解技术的研究相对较少,虽然二次分解技术可以降低风电功率数据的非线性和不稳定性,但已有的二次分解技术并未在分解后分析分量的特征,将各个分量进行了相同处理,这样会导致各分量的数据信息不能被合理提取,从而降低模型预测精度。

综上,本文提出二次分解组合LSTM的预测模型。在分解方面,本文首先采用EMD技术将原始的风电功率分解成若干固有模态分量(IMF),再利用样本熵对各个IMF分量进行复杂度分析,重组成高、中、低频3个组合分量,然后通过麻雀搜索算法(SSA)优化VMD的分解数和惩罚因子,对高频组合分量进行VMD二次分解;在预测方面,使用麻雀搜索算法优化LSTM模型的超参数,然后对每个分量建立预测模型。最后采用湖北某风电场的实测数据对所提方法的预测性能进行详细的分析和验证。

## 1 二次分解技术

### 1.1 EMD分解算法

EMD<sup>[21]</sup>是一种非线性的信号分解方法。其基本思想是将一个非线性/非平稳信号分解成若干个IMF分量和一个剩余分量 $r$ ,通过对各个IMF的回归来实现预测。

1)在原始风电功率数据 $x(t)$ 中找出极大值点和极小值点,并利用三次样条插值函数拟合,得到上包络线 $e_{up}(t)$ 和下包络线 $e_{low}(t)$ 。

2)计算出上、下包络线的均值 $h_1(t)$ :

$$h_1(t) = \frac{e_{up}(t) + e_{low}(t)}{2} \quad (1)$$

3)求解时域离散的残差函数 $r_1(t) = x(t) - h_1(t)$ ,判断 $r_1(t)$ 是否满足IMF的条件。若满足条件,则对 $r_1(t)$ 进行分解,得到剩余分量 $c(t)$ ;若不满足条件,则将 $r_1(t)$ 作为新的原始数据,重复上述步骤得到其余分量。

经过上述步骤,原始风电功率序列 $x(t)$ 被分解为:

$$x(t) = \sum_{i=1}^n r_i(t) + c_n \quad (2)$$

### 1.2 样本熵(SE)

熵值通常被用来衡量输入变量的相关性,表示数据集的不确定度。其中Richman等<sup>[22]</sup>提出的样本熵计算过程更便捷、精度更高的,此分类方法完全基于样本数据,依据样本集合中的分布规律直接计算熵值,样本熵越大,表示数据的不确定性越大。

设定时间序列 $\{x_i\}$ 为 $x(1), x(2), \dots, x(N)$ 。

1)将 $N$ 个样本数按顺序组成 $m$ 维矢量:

$$x(i) = [x(i), x(i+1) \dots x(i+m-1)] \\ i = 1, 2, \dots, N-m+1 \quad (3)$$

2)定义向量  $x(i)$  与  $x(j)$  之间的距离为:

$$d[x(i), x(j)] = \max[x(i+k) - x(j+k)] \quad (4)$$

$$0 \leq k \leq m-1$$

3)给定阈值  $r$ , 将距离小于  $r$  的两向量之间的数目与超过  $N-m$  的比值定义为  $B_i^m(r)$ :

$$B_i^m(r) = \frac{1}{N-m} \text{num}\{d_m(x(i), x(j)) < r\} \quad (5)$$

$B_i^m(r)$  的平均值为:

$$B^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (6)$$

4)增加维数  $m+1$ , 重复步骤 1)~3), 则  $B_i^m(r)$  的平均值为:

$$B^{m+1}(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^{m+1}(r) \quad (7)$$

5)SE 定义为:

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left( \frac{B^{m+1}(r)}{B^m(r)} \right) \right\} \quad (8)$$

$\text{SampEn}$  的值与  $m$  和  $r$  的取值有关, 一般情况下  $m=1$  或者  $2$ ,  $r=(0.1-0.2)SD$ ,  $SD$  表示时间序列标准差, 本文取  $m=2$ ,  $r=0.2SD$ 。

### 1.3 SSA 算法

SSA<sup>[23-25]</sup> 是一种基于自然鸟类觅食行为的启发式优化算法。该算法的优点是寻优能力强, 收敛速度快。应用麻雀算法时, 搜索空间将被划分为数个小的搜索区域, 每个区域由一个麻雀群进行搜索, 每个麻雀群中麻雀的会根据其搜索区域中的位置和当前最优解的位置来确定下一步的移动, 同时传达给整个麻雀群。借助这种信息共享的方式, 该算法能够高效地在搜索空间中找到全局最优解。

发现食物的麻雀位置更新公式为:

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \cdot \exp\left(\frac{-i}{a \cdot \text{iter}_{\max}}\right), & R_2 < ST \\ x_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (9)$$

式中:  $x_{i,j}^{t+1}$  为第  $i$  只麻雀在第  $j$  区域的位置;  $a$  为  $[0,1]$  的随机数;  $R_2$  为  $[0,1]$  的预警值;  $ST$  为  $[0.5,1]$  的安全阈值;  $Q$  为呈现正态分布的随机数;  $L$  为  $1 \cdot d$  阶单元矩阵。

觅食麻雀位置更新公式为:

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}} - x_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ x_p^{t+1} + |x_{i,d} - x_p^{t+1}| \cdot A^+ \cdot L, & i \leq \frac{n}{2} \end{cases} \quad (10)$$

$$A^+ = A^T (AA^T)^{-1} \quad (11)$$

式中:  $x_{\text{worst}}$  为当前最差位置;  $x_p^{t+1}$  为适应度最好的麻雀在第  $t+1$  次迭代时的值;  $A$  为  $1$  或  $-1$  的  $1 \cdot d$  阶矩阵。

意识到危险并发出警报的麻雀位置更新公式为:

$$x_{i,j}^{t+1} = \begin{cases} x_{\text{best}}^t + \lambda \cdot |x_{i,j}^t - x_{\text{best}}^t|, & f_i > f_g \\ x_{i,j}^t + J \left( \frac{x_{i,j}^t - x_{\text{worst}}^t}{(f_i - f_g) + \epsilon} \right), & f_i = f_g \end{cases} \quad (12)$$

式中:  $x_{\text{best}}$  为区域中的最佳位置;  $f_i, f_g$  分别为第  $i$  只麻

雀的适应度值、区域最佳适应度值。

### 1.4 SSA 优化 VMD

VMD 分解算法是一种自适应信号处理方法, 主要用来分解非平稳或非线性信号, 通过调整参数来控制分解出来的模态数量和宽度, 可以更好地适应原始信号的特性。其分解步骤参考文献[26], 本文不再赘述。

VMD 分解过程中分解次数  $K$  和惩罚系数  $\alpha$  直接影响分解效果。因此, 本文用优化算法 SSA 优化 VMD 参数, 其流程如图 1 所示。

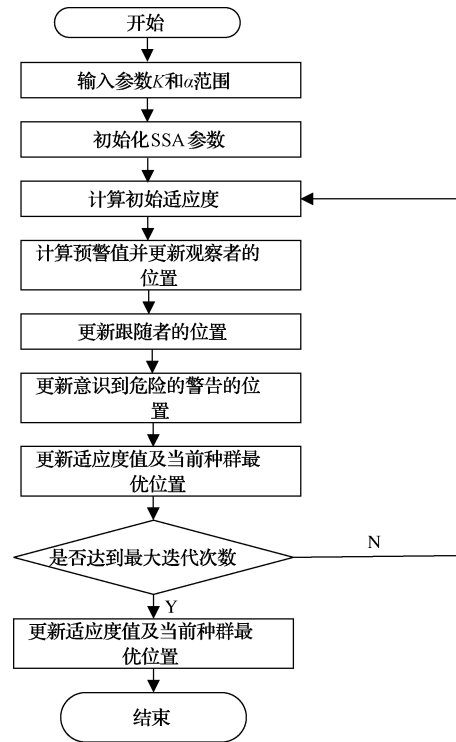


图 1 SSA-VMD 流程

## 2 LSTM 预测模型

### 2.1 LSTM 模型

LSTM 是一种常用于循环神经网络的变体, 主要贡献是加入了门机械, 通过 3 种类型的门来控制信息的输入、输出和遗忘, 实现了一种能够持续记忆的机制, 解决了普通 RNN 存在的梯度消失和爆炸的问题<sup>[27]</sup>。LSTM 的模型结构如图 2 所示。

图 2 中,  $h_t$  表示时刻  $t$  的隐藏层向量;  $c_t$  表示时刻  $t$  的元胞状态;  $W_f, W_i, W_c$  和  $W_o$  分别表示时刻  $t$  的遗忘门、输入门、候选状态和输出门的权值矩阵。此外,  $\delta$  为 Sigmoid 激活函数。输入门  $i_t$ 、遗忘门  $f_t$  和输出门  $o_t$  的计算公式如下:

$$i_t = \delta(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (13)$$

$$f_t = \delta(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (14)$$

$$o_t = \delta(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (15)$$

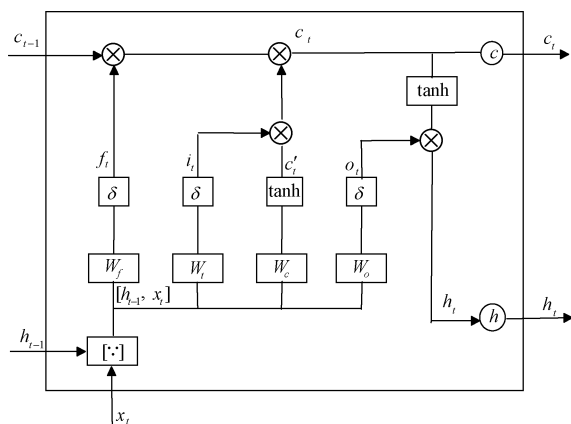


图2 LSTM模型结构

式中： $b_f$ 、 $b_i$ 、 $b_o$  分别表示3个门的偏置值。

在时刻  $t$ ，元胞状态的更新公式为：

$$c_t = f_t \odot c_{t-1} + i_t \odot c'_t \quad (16)$$

式中：“ $\odot$ ”为 Hadamard 积。

$$c'_t = \delta(W_c[h_{t-1}, x_t] + b_c) \quad (17)$$

式中： $b_c$  为偏置项。最后更新隐藏层向量为：

$$h_t = o_t \odot \varphi(c_t) \quad (18)$$

式中： $\varphi$  为双曲正切激活函数。于是有：

$$y_t \approx \delta(W_y \cdot h_t + b_y) \quad (19)$$

式中： $W_y$  为可调权重矩阵； $b_y$  为偏置项。

## 2.2 SSA-LSTM 模型

由 2.1 节可知，在 LSTM 模型中，隐藏层单元数、学习率和训练次数等超参数会对模型的预测精度产生重要影响，使用不同参数进行训练时，所得到的模型预测能力相差较大，因此，提出 SSA-LSTM 模型，使用 SSA 对 LSTM 模型的超参数进行寻优。

1) 根据 LSTM 模型的超参数（隐藏层单元数、学习率、训练次数等）随机初始化麻雀位置。

2) 选择均方误差(MSE)作为评价指标，计算每个个体的适应度函数值。

3) 随机选取 20% 的麻雀为发现者，20% 的麻雀具有意识到危险并发出警报的行为机制，其余均视为加入者。

4) 根据式(9)~(11)迭代更新发现者、警惕者、加入者的位置，进而重新计算适应度函数的值。

5) 迭代结束后，输出全局最优麻雀的位置，从而获得 LSTM 模型的最优超参数。

## 3 二次分解组合 LSTM 预测模型

### 3.1 短期风电功率预测模型

本文提出的基于二次分解组合 LSTM 模型的预测框架如图 3 所示。

1) 将原始风电功率数据  $x(t)$  输入 EMD 模型进行分解，得到一组子序列。

2) 再利用 SE 技术计算子序列的复杂度，将其重组为

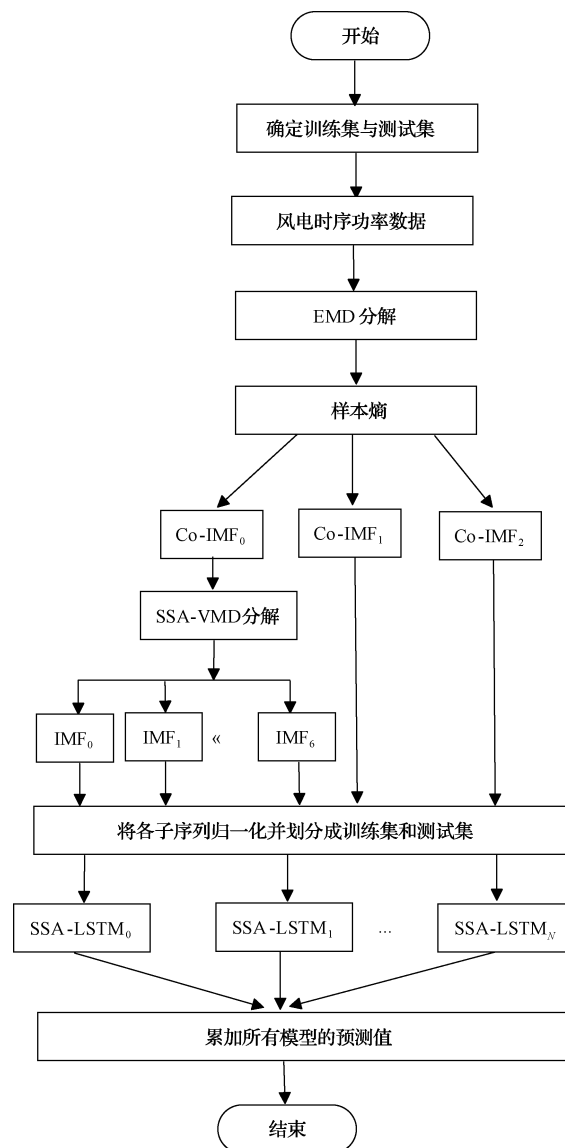


图3 EMD-SSA-VMD-LSTM 预测模型总体框架

高、中、低频 3 个序列，对高频序列再次进行 SSA-VMD 分解，然后将各子序列归一化并划分为训练集和测试集。

3) 运用 SSA 优化算法寻优 LSTM 模型的超参数（隐藏层单元数、学习率、训练次数等），将所得的最优超参数进行预测。

4) 累加所有子序列的预测值并输出最终预测结果。

### 3.2 评价指标

本文选择 MAE、均方根误差(RMSE)、平均绝对误差(MAPE)作为预测模型的误差评估指标，其定义为：

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (21)$$

$$MAPE = \frac{1}{N} \left[ \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \right] \times 100\% \quad (22)$$



式中: $N$  为采样点数; $y_i$ 、 $\hat{y}_i$  和  $\bar{y}_i$  分别为第  $i$  个采样点的实际值、预测值和平均值。

#### 4 仿真分析

为验证所设计模型的有效性,本文以湖北某风电场 2023 年 1 月 7 日~2 月 6 日采集的数据为例。数据采样间隔为 15 min,共计 2 880 组数据,前 2 500 组数据为训练集,后 380 组数据为测试集。将当前时刻的风电功率作为模型的输入,下一时刻的风电功率作为输出。原始风电功率时序如图 4 所示。




图 4 原始功率时间序列

##### 4.1 功率序列 EMD 分解

由图 4 可以看出,原始风电功率数据呈现出明显的非平稳性,因此为了更好地处理这种特性,本文首先采用 EMD 分解方法进行分解,以产生一系列 IMF 和剩余分量  $r$ 。

考虑到 EMD 分解后会产生大量的 IMF 分量,如果直接对每个分量进行建模和预测,将会极大的增加计算复杂度。根据样本熵的思想,对相似样本熵值的 IMF 进行合并为高、中、低频 3 个子序列,以降低计算规模。根据图 5 所示的各 IMF 分量的熵值,可以看出模态 1~3 呈现出一




图 5 各 IMF 分量熵

定的相似性,可以把这 3 项叠加作为高频率序列,模态 4~6 叠加作为中频率序列,模态 7~9 叠加作为低频率序列。重组后的高、中、低频率序列如图 6 所示。




图 6 高、中、低频率序列分量

##### 4.2 高频率序列 VMD 分解

由图 6 可以看出,Co-IMF0 高频分量数据变化剧烈,频率高,会影响模型的精度预测,通过 VMD 分解,可有效降低整体数据的非线性,有助于提高模型预测精度。因此,对 Co-IMF0 高频分量进行 VMD 分解。

VMD 参数设置如下:采样频率为 1 000 Hz,中心频率参数  $\text{init}$  为 1,分解次数  $K$  和惩罚系数  $\alpha$  通过 SSA 寻优得到。SSA 参数设置如下:种群规模为 20,最大迭代次数为 30,发现者与警惕者均占比 20%。表 1 为 SSA 寻优时不同的  $K$  和  $\alpha$  对应的样本熵值,由表 1 可见,寻优的 VMD 最优参数  $K=7$ , $\alpha=1\ 024$ ,此时布局样本熵的值最小。VMD 分解后的各个分量的波形如图 7 所示。

表 1 不同  $K$  和  $\alpha$  值对应的样本熵值

分解次数 $K$	惩罚系数 $\alpha$	样本熵值
5	696	0.226 6
6	847	0.226 4
7	1 024	0.224 6
8	978	0.224 7

##### 4.3 二次分解组合 LSTM 的模型预测结果

LSTM 参数设置:迭代次数为 100 次,初始学习率为 0.005,求解器选择 Adam,隐藏层数为 2 层,层数分别为 100、50。为了避免出现过拟合问题,给 LSTM 每一层加入失活概率为 20% 的随机失活(Dropout)层。根据上述分




图7 高频各子序列分量

解后的模态分量建立 LSTM 模型,然后分别进行预测,最终的预测结果如图 8 所示。




图8 EMD-SSA-VMD-LSTM 预测结果

#### 4.4 预测结果分析

为了进一步验证本文模型的有效性,将其与其他 9 种常用的预测模型进行比较。这 9 种模型包括 BP、LSTM、EMD-LSTM、VMD-LSTM、EMD-VMD-LSTM、EMD-PSO-LSTM、EMD-SSA-LSTM、VMD-PSO-LSTM、VMD-SSA-LSTM。10 种预测模型的误差评价结果如表 2 所示。

对比表 2 中 BP、LSTM、EMD-LSTM 和 VMD-LSTM 模型,单独使用 BP 的预测效果最差,使用分解方法对风电功率数据进行预测的误差较小,表明将风电功率数据进行分解再预测可以提升 LSTM 的学习效果。与 LSTM 相比,EMD-LSTM、VMD-LSTM、EMD-VMD-LSTM 的预测误差 MAE 分别降低了 36.55%、39.70%、49.47%;RMSE 分别降低了 37.76%、51.64%、71.93%;MAPE 分别降低了 2.90%、2.54%、57.62%。EMD-VMD 分解的

表2 不同模型误差评价

预测模型	MAE /kW	RMSE /kW	MAPE /%
BP	41.25	57.42	64.91
LSTM	33.68	50.87	43.12
EMD-LSTM	21.37	31.66	42.55
VMD-LSTM	20.31	24.60	42.11
EMD-VMD-LSTM	17.02	14.28	19.63
EMD-PSO-LSTM	19.46	25.72	41.87
EMD-SSA-LSTM	18.27	22.05	41.55
VMD-PSO-LSTM	15.58	14.16	39.39
VMD-SSA-LSTM	14.72	10.28	37.85
EMD-SSA-VMD-LSTM	5.79	5.64	17.38

提升效果最为显著,这是因为 VMD 在 EMD 分解的基础上,对于高频鲁棒性更强、分解效果更好。

对比表 2 中 EMD-LSTM、VMD-LSTM、EMD-PSO-LSTM、VMD-PSO-LSTM、EMD-SSA-LSTM、VMD-SSA-LSTM 的预测误差,发现使用优化算法的预测模型优于未使用优化算法的模型,且使用 SSA 优化算法优于 PSO 算法。相比于 PSO 优化算法,使用 SSA 的 MAE、RMSE、MAPE 分别提升 6.12%、16.64%、3.91%。这是因为其具有更快的搜索速度和更好的搜索精度,易于实现且不需要梯度信息。

对比表 2 中的 EMD-SSA-LSTM、VMD-SSA-LSTM 和 EMD-SSA-VMD-LSTM 进行比较,可以明显看出 EMD-SSA-VMD-LSTM 模型的预测效果更为准确。

综上所述,单独使用 EMD 或 VMD 的方法能够有效减少误差,将两者结合起来进行预处理效果更为显著。而采用 SSA 和 EMD-VMD 二次分解技术联合预处理的方法,再利用 LSTM 模型进行预测,预测效果更好。

#### 5 结论

本文通过对采集到的风电功率数据进行分析,结合风力发电的特点,提出了二次分解组合 LSTM 的短期风电功率预测模型,并得出如下结论。

1)本文引入 EMD-VMD 二次分解技术,克服了原始风电功率的不平稳性,解决了模态混叠问题,从预处理环节提高预测精度。

2)对 VMD 分解次数  $K$  和惩罚系数  $\alpha$ 、LSTM 模型的超参数进行 SSA 优化,进一步提高模型的预测精度。

3)最后通过湖北某风电场实测数据进行验证,并与其他 9 种模型对比分析,本文所提模型的 MAE 小、RMSE 小、MAPE 小,表明了本文所提模型具有更好的稳定性和更高的预测精度。

## 参考文献

- [1] 杨锡运,张艳峰,叶天泽,等.基于朴素贝叶斯的风电功率组合概率区间预测[J].高电压技术,2020,46(3):1099-1108.
- [2] 杨子民,彭小圣,郎建勋,等.基于集群动态划分与BLSTM深度学习的风电集群短期功率预测[J].高电压技术,2021,47(4):1195-1203.
- [3] 李继超,胡文婷,陈超波,等.基于自抗扰控制的风电机组限功率算法研究[J].国外电子测量技术,2022,41(5):118-123.
- [4] LAHOUE A, BEN H S J. Hour-ahead wind power forecast based on random forests [J]. Renewable Energy, 2017, 109: 529-541.
- [5] 孙荣富,张涛,和青,等.风电功率预测关键技术及应用综述[J].高电压技术,2021,47(4):1129-1143.
- [6] 赵宇洋,赵浩然,谭建鑫,等.面向风电制氢的超短期组合功率预测[J].太阳能学报,2023,44(3):162-168.
- [7] 冯双磊,王伟胜,刘纯,等.基于物理原理的风电场短期风速预测研究[J].太阳能学报,2011,32(5):611-616.
- [8] 孙斌,姚海涛,刘婷.基于高斯过程回归的短期风速预测[J].中国电机工程学报,2012,32(29):104-109.
- [9] 赵攀,戴义平,夏俊荣,等.卡尔曼滤波修正的风电场短期功率预测模型[J].西安交通大学学报,2011,45(5):47-51.
- [10] WANG G, JIA R, LIU J, et al. A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning [J]. Renewable Energy, 2020, 145(6): 2426-2434.
- [11] 谢波,高建宇,张惠娟,等.短期风电功率预测中的IOFA-SVM算法实现[J].电子测量技术,2021,44(12):63-69.
- [12] 赵智辉,张君胜,何培东,等.基于宽度-深度神经网络的风电功率预测方法[J].中国电子科学研究院学报,2019,14(3):307-311.
- [13] 唐振浩,孟庆煜,曹生现,等.基于小波深度置信网络的风电爬坡预测方法[J].太阳能学报,2019,40(11):3213-3220.
- [14] 陈海鹏,周越豪,王趁录,等.基于改进的CNN-LSTM短期风功率预测的系统旋转备用经济性分析[J].高电压技术,2022,48(2):439-448.
- [15] 王梓齐,张书瑶,刘长良.基于增量式相对熵的风电机组实时状态监测[J].电子测量与仪器学报,2020,34(12):125-132.
- [16] 谢丽娟,路锋,王旭,等.一种用于信号去噪的小波阈值去噪算法[J].国外电子测量技术,2020,39(4):32-36.
- [17] 文孝强,许洋.基于EMD分解的风力机功率特性分析与预测建模[J].太阳能学报,2021,42(11):293-298.
- [18] 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.
- [19] 王贺,胡志坚,陈珍,等.基于集合经验模态分解和小波神经网络的短期风功率组合预测[J].电工技术学报,2013,28(9):137-144.
- [20] 周小龙,徐鑫莉,王尧,等.基于变分模态分解和最大重叠离散小波包变换的齿轮信号去噪方法[J].振动与冲击,2021,40(12):265-274, 289.
- [21] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [22] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy[J]. American Journal of Physiological Heat and Circulatory Physiology, 2000, 278(6): 2039-2049.
- [23] 王雨虹,王志中,付华,等.多策略改进麻雀算法与BiLSTM的变压器故障诊断研究[J].仪器仪表学报,2022,43(3):87-97.
- [24] MEMARZADEH G, KEYNIA F. A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets [J]. Energy Conversion and Management, 2020, 213: 1-15.
- [25] CHEN G, LI L, ZHANG Z, et al. Short-term wind speed forecasting with principle-subordinate predictor based on Conv-LSTM and improved BPNN[J]. IEEE Access, 2020, 8: 67955-67973.
- [26] 王粟,江鑫,曾亮,等.基于VMD-DESN-MSGP模型的超短期光伏功率预测[J].电网技术,2020,44(3):917-926.
- [27] 李俊卿,李秋佳.基于Kriging和长短期记忆网络的风电功率预测方法[J].太阳能学报,2020,41(11):241-247.

## 作者简介

杨生鹏,硕士研究生,主要研究方向为新能源发电出力预测。

E-mail:860295415@qq.com

文中,副教授,主要研究方向为风电功率预测、电力系统运行与控制。

E-mail:1121171656@qq.com

丁剑,工程师,主要研究方向为输电线路设计。

E-mail:1748633501@qq.com

张开伟,硕士研究生,主要研究方向为风电功率曲线与整机状态检测。

E-mail:2791415163@qq.com

张业伟,硕士研究生,主要研究方向为风电功率曲线与整机状态检测。

E-mail:1654552907@qq.com

倪志,硕士研究生,主要研究方向为风电功率曲线与整机状态检测。

E-mail:937918347@qq.com