

# 基于组合模态分解和深度学习的短期风电功率区间预测

肖 白, 张 博, 王辛玮, 高宁远  
(东北电力大学电气工程学院, 吉林省吉林市 132012)

**摘要:** 风电功率预测对含风电的电力系统经济调度十分重要。针对点预测难以描述风电功率不确定性的问题,提出一种基于组合模态分解和深度学习的短期风电功率区间预测方法。首先,利用改进自适应噪声完备集合经验模态分解将原始风电功率序列分解为多个模态分量,并使用变分模态分解对其中的高频强非平稳分量再次分解。在此基础上,使用样本熵计算各分量复杂度并将其重构为趋势分量、振荡分量和随机分量。然后,将3个分量分别输入经贝叶斯优化的双向长短期记忆神经网络建立各自的预测模型,得到3个分量的点预测值,并用混合核密度估计方法对振荡分量和随机分量预测结果的误差分布进行估计,再结合点预测值得到总体的区间预测结果。最后,通过实际算例分析表明,与其他模型相比该方法具有更高的预测精度。

**关键词:** 风电功率预测; 长短期记忆; 深度学习; 区间预测; 经验模态分解; 核密度估计

## 0 引言

随着各国对环保的重视以及能源结构体系的改变,风电并网的规模快速扩大。然而,风电的波动性和随机性给风电并网带来了严峻挑战。因此,风电功率的准确预测,对合理安排系统备用、保证电网稳定运行和提高经济效益具有重要意义<sup>[1-3]</sup>。

目前,已有众多学者对风电功率预测展开了深入研究,并且在点预测方面取得了显著成果。随着人工智能的兴起,神经网络和深度学习等<sup>[4-7]</sup>人工智能方法在挖掘数据特征和数据处理方面展现出了良好的能力。然而,点预测难以表征风电功率的不确定性,区间预测则是量化风电不确定性引起预测结果偏差的有力工具<sup>[8]</sup>,在给出点预测结果的同时描绘出风电功率波动的区间,更有利于合理安排备用容量、火电机组开机计划等。

文献[9]通过分位数回归方法对风电功率进行区间预测,但需要预先确定分位点和回归模型,计算量较大。文献[10]提出一种基于变分模态分解(variational mode decomposition, VMD)和相关向量机的短期区间预测方法,但预测结果需依赖于核函数的选择。文献[11]采用Bootstrap重抽样法构造伪样本得到预测功率误差区间,但该方法需要处理的数据量较多,耗时较长。文献[12]对敏感气象因

子的误差分布函数进行了估计,并提出一种Monte-Carlo随机抽样方法得到区间预测结果,但需要有气象数据支持。文献[13]将噪声成分进行模糊信息化处理,建立了基于极限学习机的风速区间预测模型,但其时序记忆能力不佳。随着深度学习的广泛应用,其对数据的时序记忆能力和特征挖掘的优势展现了出来。文献[14]提出一种基于多位置数值天气预报和门控循环单元的风电功率超短期预测模型,取得了较好的预测效果。文献[15-17]采用长短期记忆神经网络进行预测,也取得了不错的效果。文献[18-19]采用VMD将风电功率时间序列进行分解,再对各子序列进行预测,最后对各子序列预测结果进行重构。文献[20]采用经验模态分解将光伏功率时间序列进行分解,然后输入支持向量机进行预测。这些通过分解后再预测的方法,虽然预测精度有所提高,但是分解时存在频谱混叠问题,分解产生的高频强非平稳分量也会导致较大的预测误差。文献[21-23]对时间序列数据进行二次分解处理再预测,提高了对一次分解中高频分量部分的预测精度,但产生的子分量数量过多,分别预测需要的时间较长。

鉴于此,本文提出一种基于二次模态分解、样本熵、深度学习和混合核密度估计的短期风电功率区间预测方法。首先,针对风电功率时间序列的随机性和一次模态分解产生的高频强非平稳分量的问题,采用合适的模态分解方法对风电功率时间序列进行二次分解;然后,利用样本熵(sample entropy, SE)将子分量重构为具有典型特征的3个分量,再

收稿日期: 2022-08-07; 修回日期: 2022-11-18。

上网日期: 2023-02-20。

国家重点研发计划资助项目(2017YFB0902205);吉林省产业创新专项基金资助项目(2019C058-7)。

利用贝叶斯优化的双向长短期记忆神经网络进行点预测;最后,运用混合核密度估计方法进行概率区间构造。与多个经典模型相比,本文所提模型均有更高的预测精度。

## 1 风电功率区间预测基本原理

本文结合改进自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode

decomposition with adaptive noise, ICEEMDAN)、VMD、SE、贝叶斯优化的双向长短期记忆(Bayesian optimization bidirectional long short-term memory, BO-BiLSTM)神经网络及混合核密度估计(mixed kernel density estimation, MKDE)方法建立了风电功率区间预测模型,其基本原理图如图1所示。图中:res表示残余分量。

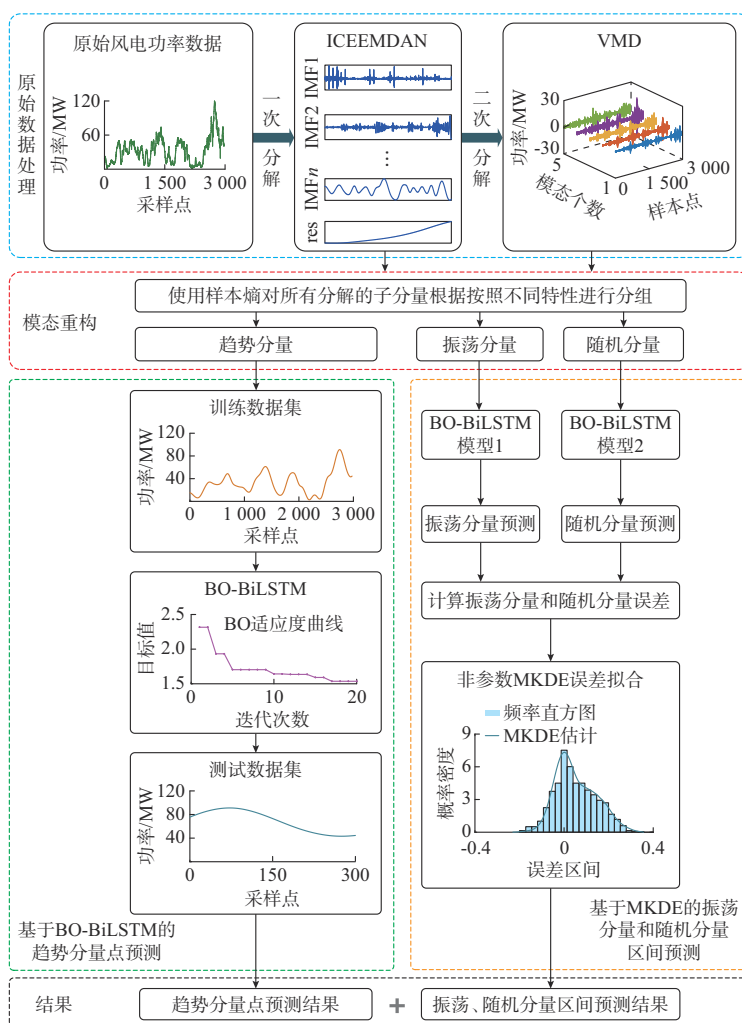


图1 所提方法基本原理图

Fig. 1 Basic principle diagram of proposed method

针对风电功率时间序列的非平稳性和一次模态分解产生的高频强非平稳分量给预测精度带来的影响,采用ICEEMDAN和VMD进行二次模态分解处理。考虑到分解后子分量过多,其数据处理繁琐且需要训练的时间过长,使用SE对得到的子分量进行复杂度分析,将具有相关性的子分量进行重组,分为具有典型特征的3组分量,并重构为风电功率时间序列的趋势分量、振荡分量和随机分量。

在风电功率的点预测阶段,采用能够充分挖掘

时间序列时序特征的BiLSTM神经网络进行预测,并用贝叶斯优化(BO)算法对神经网络的超参数进行优化,得到趋势分量、振荡分量和随机分量的点预测值。

在风电功率的预测区间构造阶段,利用MKDE方法对振荡分量和随机分量的预测误差进行误差分布估计,进行概率区间预测,再叠加点预测值得到总体的预测区间。

## 2 风电功率数据处理

### 2.1 基于 ICEEMDAN 的风电功率时间序列分解

ICEEMDAN 是一种改进自适应噪声完备集合经验模态分解方法,与完备集合经验模态分解 (CEEMDAN) 方法的原理不同,ICEEMDAN 是利用白噪声被经验模态分解方法分解后的模态分量 (IMF) 来解决残留噪声和伪模态的问题。该方法在解决模态混叠问题的同时使 IMF 中残余噪声大大降低,对风电功率时间序列中所包含的不同尺度成分具有良好的分解和特征提取能力。使用 ICEEMDAN 对风电功率时间序列进行分解的基本步骤如下。

1) 设  $x$  为原始风电功率时间序列,把特殊噪声  $E_k(w^{(i)})$  添加到  $x$  中,见式(1)。

$$x^{(i)} = x + \beta_1 E_k(w^{(i)}) \quad (1)$$

式中: $\beta_1$  为第 1 次分解的迭代期望信噪比; $E_k(\cdot)$  为经验模态分解产生的  $k$  阶模态分量; $w^{(i)}$  表示用于辅助分解的第  $i$  组白噪声; $x^{(i)}$  为添加第  $i$  组特殊噪声后的风电功率时间序列。

2) 计算第 1 次分解的残差  $r_1$ ,并用原始风电功率时间序列  $x$  减去残差得到模态分量  $d_1$ ,见式(2)和式(3)。

$$r_1 = \frac{1}{I} \sum_{i=1}^I M(x + \beta_1 E_k(w^{(i)})) \quad (2)$$

$$d_1 = x - r_1 \quad (3)$$

式中: $M(\cdot)$  为产生信号局部均值的操作符; $I$  为白噪声组数。

3) 继续添加白噪声信号,计算第 2 个残差,求出原始风电功率时间序列的二阶模态分量  $d_2$ ,见式(4)和式(5)。

$$r_2 = \frac{1}{I} \sum_{i=1}^I M(r_1 + \beta_2 E_2(w^{(i)})) \quad (4)$$

$$d_2 = r_1 - r_2 \quad (5)$$

4) 与步骤 3 同理,计算第  $k$  个残差和模态分量,见式(6)和式(7)。

$$r_k = \frac{1}{I} \sum_{i=1}^I M(r_{k-1} + \beta_k E_k(w^{(i)})) \quad (6)$$

$$d_k = r_{k-1} - r_k \quad (7)$$

5) 重复步骤 4,直到达到最高迭代次数或者残差不能再分解。

### 2.2 基于 VMD 的高频强非平稳分量的二次分解

ICEEMDAN 产生的 IMF1 为高频强非平稳分量,直接对其进行预测会产生较大误差,因此对分解出的高频强非平稳分量 IMF1 使用 VMD 再次进行

分解。二次模态分解对提高风电功率预测精度影响的详细分析见附录 A,VMD 分解的基本步骤如下。

1) 建立变分问题,假设风电功率序列分解出的高频强非平稳分量 IMF1 被分解为  $K$  个子分量。使子分量具有最小的估计带宽和,并确保子分量为具有中心频率有限带宽的模态分量,表达式见式(8)。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{k=1}^K u_k = f(t) \end{cases} \quad (8)$$

式中: $K$  为分解出的模态数; $u_k, \omega_k$  分别为高频非平稳分量 IMF1 被分解后的第  $k$  个子分量和它的中心频率; $u_k(t)$  为第  $k$  个模态分量在  $t$  时刻的值; $*$  为卷积运算符; $\|\cdot\|_2^2$  表示二范数的平方; $\partial_t$  表示求偏导数; $\delta(t)$  为狄拉克函数; $f(t)$  为原始风电功率序列分解出的高频强非平稳分量。

2) 转变为非约束变分问题,加入惩罚项  $\alpha$ 、Lagrange 乘法算子  $\lambda$ ,见式(9)。

$$L(\{u_k\}, \{\omega_k\}, \lambda) =$$

$$\begin{aligned} & \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (9)$$

式中: $L(\cdot)$  为拉格朗日函数; $\langle \cdot \rangle$  表示内积。

3) 利用交替方向乘子迭代算法和傅里叶等距变换对  $u_k$  和  $\omega_k$  进行优化,并对每次迭代精度进行判别,达到所需精度则完成迭代输出各分量。

### 2.3 基于 SE 的风电功率模态分量重构

若对经过两次模态分解获得的各模态分量都分别进行预测,会大幅增加计算量,并且忽视了子分量之间的相关性,将具有相关性的分量进行分类再处理,不仅可以缩短运算时间,而且能突显同类分量的特性。因此,采用信息论中的熵定律对子分量进行处理。

SE 是基于近似熵的一种用于度量时间序列复杂性的改进方法<sup>[6]</sup>,SE 的值越低,表示时间序列自我相似性越高、复杂程度越低。与近似熵对比,SE 不依赖于数据长度,并且具有更好的一致性,SE 的计算式见式(10)。

$$\text{Sampen}(m, r, N) = -\text{Ln} \left( \frac{B^{m+1}(r)}{B^m(r)} \right) \quad (10)$$

式中:Sampen( $\cdot$ ) 为 SE 计算函数; $N$  为模态分量的



长度; $B^m(r)$ 、 $B^{m+1}(r)$ 分别为序列在容限 $r$ 下匹配 $m$ 个点和 $m+1$ 个点的概率;在实际场景中, $m$ 为维数,一般取2; $r$ 为容限,通常取所计算数据标准差(SD)的10%~25%,本文 $r$ 取SD的20%。

考虑分解后子分量过多,直接对分解后的所有子分量进行建模预测,其数据处理繁琐且需要训练的时间过长,因此利用SE对各子分量进行复杂性评估,将SE相近的分量重构成趋势分量、振荡分量和随机分量后再进行预测。

### 3 基于BO-BiLSTM神经网络的风电功率点预测

#### 3.1 BiLSTM神经网络

长短期记忆(LSTM)保留了传统前馈神经网络的优点,并加入了网络自反馈机制<sup>[24]</sup>,有效缓解了循环神经网络(recurrent neural network, RNN)在训练过程中可能会出现的梯度弥散等问题,加快了模型的收敛速度。LSTM的基本结构如附录B图B1所示。

LSTM记忆单元模块中含有遗忘门、输入门以及输出门, $x_t$ 为 $t$ 时刻的输入向量、 $c_{t-1}$ 为 $t-1$ 时刻的记忆单元状态、 $h_{t-1}$ 为 $t-1$ 时刻的隐含层状态,将它们作为记忆单元模块 $t$ 时刻的输入量,见式(11)至式(13)。

$$f_t = \text{sig}(W_{hf}h_{t-1} + W_{xf}x_t + b_f) \quad (11)$$

$$i_t = \text{sig}(W_{hi}h_{t-1} + W_{xi}x_t + b_i) \quad (12)$$

$$o_t = \text{sig}(W_{ho}h_{t-1} + W_{xo}x_t + b_o) \quad (13)$$

式中: $f_t$ 为遗忘门的信息; $i_t$ 为输入门的信息; $o_t$ 为输出门的信息; $W_{hf}$ 、 $W_{xf}$ 、 $W_{hi}$ 、 $W_{xi}$ 、 $W_{ho}$ 、 $W_{xo}$ 分别为遗忘门、输入门、输出门和 $h_{t-1}$ 、 $x_t$ 的连接权值矩阵; $b_f$ 、 $b_i$ 、 $b_o$ 分别为遗忘门、输入门、输出门的偏置向量; $\text{sig}(\cdot)$ 为sigmoid函数。

记忆单元模块的外部输出信息 $c_t$ 、 $h_t$ 见式(14)至式(16)。

$$c'_t = \tanh(W_{hc}h_{t-1} + W_{hx}x_t + b_c) \quad (14)$$

$$c_t = f_t \times c_{t-1} + i_t \times c'_t \quad (15)$$

$$h_t = o_t \times \tanh(c_t) \quad (16)$$

式中: $c'_t$ 为 $t$ 时刻输入记忆单元模块的信息; $b_c$ 为预备信息偏置向量; $W_{hc}$ 、 $W_{hx}$ 分别为 $h_{t-1}$ 、 $x_t$ 与 $c'_t$ 的连接权值矩阵; $\tanh$ 为双曲正切函数。

虽然LSTM克服了RNN在预测长时间序列上的局限性,但LSTM只对风电功率时间序列进行单方向的训练,难以学习全部的数据信息,容易忽略数据前后的相关性,时序预测中考虑数据的正反向信息规律,可以提高预测精度<sup>[25]</sup>。BiLSTM在架构上

包含前向和后向2个LSTM结构,见附录B图B2,前向层和后向层的输入由输出层同时处理,综合考虑了前向和后向输入和输出之间的时间相关性信息,具有更加优越的性能。神经网络更新可以表述为式(17)。

$$\begin{cases} \vec{h}_t = H(W_1x_t + W_2\vec{h}_{t-1} + \vec{b}) \\ \overleftarrow{h}_t = H(W_3x_t + W_5\overleftarrow{h}_{t-1} + \vec{b}) \\ y_t = W_4\vec{h}_t + W_6\overleftarrow{h}_t + b_y \end{cases} \quad (17)$$

式中: $\vec{h}_t$ 为隐藏层的前向输出; $\overleftarrow{h}_t$ 为隐藏层的后向输出; $y_t$ 为最终输出; $H(\cdot)$ 为单元函数; $W_1 \sim W_6$ 为对应的权重系数; $\vec{b}$ 、 $\overleftarrow{b}$ 、 $b_y$ 为偏置向量。

#### 3.2 构建BO-BiLSTM神经网络模型

神经网络的超参数是影响其预测性能的主要因素之一。神经网络的超参数优化通常被认为是一个黑箱问题,根据经验或者多次尝试为算法选择网络超参数既耗时又不总是能够提高算法的性能。

贝叶斯优化使用一个不断更新的概率模型,通过较少次数的目标函数评估来更新优化函数的后验概率<sup>[26]</sup>,在短时间内找到更好的超参数。贝叶斯优化的目的是找到 $x_s \in X_s$ 使下式成立。

$$x^* = \arg \max f(x_s) \quad (18)$$

式中: $x^*$ 为最优超参数集,本文的优化参数包括批处理大小、隐藏层神经元个数、学习率和迭代次数; $f(x_s)$ 为目标函数; $x_s$ 为在 $X_s$ 范围中的一组超参数,其中 $X_s$ 为总的超参数组合。

采用BO对BiLSTM网络的超参数进行调优,改善网络的预测性能。BO-BiLSTM预测模型的流程见附录B图B3,其具体步骤如下:

1)初始化模型,BiLSTM采用Adam求解器;设定超参数的取值范围;输入数据集,并划分成训练数据集和测试数据集。

2)根据设定的模型超参数的取值范围,随机产生初始化样本点,将初始化的样本点输入高斯过程中,对BiLSTM进行训练,利用BiLSTM目标函数输出的损失值对高斯模型进行修正。

3)利用采集函数在修正后的高斯模型中选取下一组需要评估的样本点,输入BiLSTM进行训练,获得目标函数新的输出值,更新样本集合和高斯模型。

4)目标函数损失值若符合要求,则终止算法并退出。

5)若新选取的样本点对应的目标函数损失值不符合要求,则返回步骤3),继续更新高斯模型。

### 4 基于MKDE的预测误差置信区间

点预测模型结果都不可避免会与实际值存在误差。同时,由于风电具有随机性、波动性等内在特性,点预测无法给出其可能的波动范围及其可能出现的概率,这使得在某些情况下仅仅得到风电功率的点预测值是不够的,因此,需要对风电功率进行区间预测。为进一步缩小预测区间、简化计算,本文使用MKDE方法对振荡分量和随机分量的点预测误差进行概率密度函数拟合,估计该误差的分布,再结合振荡分量和随机分量的点预测值得到它们的区间预测结果。

核密度估计(kernel density estimation, KDE)方是一种数据驱动的非参数估计方法,具有原理简单、适应性强等优点。KDE主要是借助一个移动窗口对样本的密度进行估计,而概率密度函数的窗口带宽选择会对估计精度产生影响,因此利用“混合”思想,把不同带宽估计的概率密度函数通过合适的权重系数进行混合,使其估计误差可以相互抵消,从而使综合概率密度函数达到能更准确估计风电功率预测误差的目的,其表达式见式(19)至式(21)。

$$f_{m_0}(x) = \frac{1}{Nh_{m_0}} \sum_{i_s=1}^{N_s} K\left(\frac{x-x_{i_s}}{h_{m_0}}\right) \quad (19)$$

$$f_{MKDE}(x) = \sum_{m_0=1}^M e_{m_0} f_{m_0}(x) \quad (20)$$

$$\sum_{m_0=1}^M e_{m_0} = 1 \quad (21)$$

式中: $h_{m_0}$ 为窗口 $m_0$ 的宽; $N_s$ 为样本总数; $K(\cdot)$ 为核函数; $x_{i_s}$ 为第 $i_s$ 个预测误差样本; $x$ 为随机变量; $e_{m_0}$ 为 $f_{m_0}(x)$ 的权重系数, $f_{m_0}(x)$ 为窗宽为 $h_{m_0}$ 的核密度表达式; $f_{MKDE}(x)$ 为混合核密度的表达式; $M$ 为带宽总数。

通过MKDE得到振荡分量和随机分量的预测误差的概率密度函数后,积分即可得到其概率分布函数 $F(e)$ 。在显著性水平为 $\alpha'$ 时,若误差样本 $e$ 落在区间 $[e_d, e_u]$ 的概率不小于 $1-\alpha'$ ,则区间 $[e_d, e_u]$ 为置信水平为 $1-\alpha'$ 的置信区间,叠加到点预测值上即可得到风电预测区间,如式(22)、式(23)所示。

$$P_{re,u,t} = \begin{cases} P_{re,t} + e_u & P_{re,t} + e_u < P_e \\ P_e & P_{re,t} + e_u \geq P_e \end{cases} \quad (22)$$

$$P_{re,d,t} = \begin{cases} 0 & P_{re,t} + e_d < 0 \\ P_{re,t} + e_d & P_{re,t} + e_d \geq 0 \end{cases} \quad (23)$$

式中: $e_u, e_d$ 分别为误差置信区间上、下限, $P_{re,u,t}, P_{re,d,t}$ 分别为功率预测区间的上、下限; $P_e$ 为额定功率; $P_{re,t}$ 为趋势分量、振荡分量和随机分量的点预测值之和。

### 5 算例分析

本文以中国西北某地一个装机容量为200 MW的风电场在2019年1月1日到2019年1月31日的实测风电功率数据为例进行分析,其采样间隔为15 min,相关原始数据已共享(详见本文支撑数据)。分别将前30 d、前26 d和前21 d的数据作为训练集,后1 d、后5 d、后10 d的数据作为测试集进行多案例分析。其中,训练集用来建立预测模型,测试集用来验证模型的预测效果。

#### 5.1 风电功率时间序列的模态分解结果

原始的风电功率时间序列和第1次分解得到的子分量见附录B图B4。使用VMD对IMF1进行第2次分解,分解结果见附录B图B5。因为在VMD过程中需要预先设定子分量数,但子分量数过大会产生额外的噪声,过小又会导致模态欠分解,此处参考了文献[10]的方法来确定VMD的子分量数。

利用SE对两次分解出的子分量进行复杂性评估,将ICEEMDAN分解得到的子分量顺序记为子分量1至11,VMD分解子分量1(IMF1)得到的分量记为子分量12至16。由图2基于SE的重构结果可知,子分量7至11的SE接近,说明它们产生新模式的概率大小基本一致,可以重构作为一个分量进行预测,重构后的波形见附录B图B6。重构得到的分量可以大致反映原始功率的总体趋势,所以称该重构分量为趋势分量。同理,将SE接近的子分量5、6、15、16重构为振荡分量,将SE接近的子分量2至4、12至14重构为随机分量。




图2 基于SE的重构结果  
Fig. 2 Reconstruction result based on SE

#### 5.2 点预测结果分析

采用2019年1月共31 d的数据进行算例分析,分别以前21 d、前26 d和前30 d的数据作为训练集,对应剩余的10 d、5 d和1 d的数据作为测试集进行建模预测分析。为检验本文方法的预测效果,选取反向传播(BP)、支持向量机(SVM)、LSTM这3种方法与本文方法(BO-BiLSTM)进行对比,用均方根误差(root mean square error, RMSE)和平均绝对

误差(mean absolute error, MAE)指标进行评价。表1为本文模型和其他3种模型预测结果的评价指标值。当测试集为10 d时,本文方法与BP、SVM和单一LSTM方法相比, RMSE 指标值分别下降了1.15、2.95和0.79, MAE 指标值分别下降了2.66、2.81和0.54;当测试集为5 d和1 d时,本文方法的RMSE和MAE指标值也都低于其他3种方法。由此可得,本文方法相比其他3种方法具有更高的点预测精度。

表1 不同测试集的点预测结果误差

Table 1 Errors of point prediction results of different test sets

模型	MW					
	测试集为10 d		测试集为5 d		测试集为1 d	
	RMSE	MAE	RMSE	MAE	RMSE	MAE
BP	11.21	10.87	5.52	3.97	3.51	2.61
SVM	13.01	11.02	6.12	4.25	4.55	3.69
LSTM	10.85	8.75	4.55	3.23	2.68	2.07
BO-BiLSTM	10.06	8.21	3.94	3.10	2.05	1.73

选取预测精度最高的1月31日的点预测结果进行分析。由表1和附录B图B7可知,本文所提出的BO-BiLSTM方法的预测结果与真实值拟合度更高,能更准确地跟随实际风电功率波动,在预测精度上高于其他3种预测方法。BO-BiLSTM模型比LSTM模型的RMSE指标和MAE指标分别降低了23.5%和16.4%,说明通过引入BO对BiLSTM神经网络参数的优化,取得了更好的预测效果。

### 5.3 区间预测结果分析

为测试MKDE拟合预测误差分布的准确性,设置了多个对比模型,包括Bootstrap估计、高斯分布(normal distribution, ND)估计和KDE方法。采用预测区间覆盖率(prediction interval coverage probability, PICP)和标准化预测区间平均宽度(prediction interval normalized average width, PINAW)对区间预测效果进行评价。

由图3可以看出,在同一置信水平下, MKDE方法在满足PICP要求的条件下,比KDE方法、ND估计方法和Bootstrap估计方法具有更小的PINAW值,说明MKDE方法比其他3种方法具有更好的拟合效果。

图4为1月31日的区间预测结果。风电功率的实测值中有93个点落在置信水平为95%的置信区间内,说明本文提出的基于点预测与误差分布估计相结合的方法,能够在得到精度较高的点预测值的同时,提高区间预测的可靠性。




图3 区间预测的评价指标

Fig. 3 Evaluation index of interval prediction

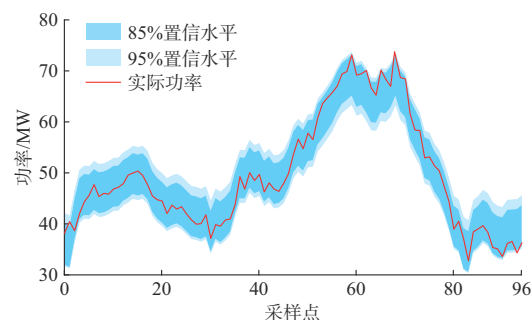


图4 两种置信水平下的风电功率区间预测结果  
Fig. 4 Prediction results of wind power interval under two confidence levels

## 6 结语

本文提出了一种基于组合模态分解和深度学习的短期风电功率区间预测方法,具有以下优点:

1)在风电数据处理中运用二次模态分解和SE技术,能够有效降低一次分解中高频强非平稳分量的不利影响,在简化模型的同时为模型预测性能的提升创造有利条件。

2)运用BiLSTM神经网络并引入BO对其参数进行优化,能够更好地学习历史数据的整体信息,提



高风电功率点预测的预测精度。

3) 采用MKDE方法对振荡分量和随机分量的预测误差分布进行估计,能够有效地降低风电功率区间预测的标准化预测区间平均宽度。

后续工作可以在本文基础上增加输入的特征维度,将数值天气预报等相关信息也输入预测模型,进一步提高预测精度。

本文风电功率原始数据已共享,可在本刊网站支撑数据处下载(<http://www.aeps-info.com/aeps/article/abstract/20220807002>)。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

## 参 考 文 献

- [1] 薛禹胜,郁琛,赵俊华,等.关于短期及超短期风电功率预测的评述[J].电力系统自动化,2015,39(6):141-151.  
XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction [J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.
- [2] EZZAT A A, JUN M, DING Y. Spatio-temporal asymmetry of local wind fields and its impact on short-term wind forecasting [J]. IEEE Transactions on Sustainable Energy, 2018, 9(3): 1437-1447.
- [3] 杨茂,周宜.计及风电场状态的风电功率超短期预测[J].中国电机工程学报,2019,39(5):1259-1268.  
YANG Mao, ZHOU Yi. Ultra-short-term prediction of wind power considering wind farm status [J]. Proceedings of the CSEE, 2019, 39(5): 1259-1268.
- [4] 孔祥玉,郑锋,鄂志君,等.基于深度信念网络的短期负荷预测方法[J].电力系统自动化,2018,42(5):133-139.  
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network [J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [5] 李丹,任洲洋,颜伟,等.基于因子分析和神经网络分位数回归的月度风电功率曲线概率预测[J].中国电机工程学报,2017,37(18):5238-5247.  
LI Dan, REN Zhouyang, YAN Wei, et al. Month-ahead wind power curve probabilistic prediction based on factor analysis and quantile regression neural network [J]. Proceedings of the CSEE, 2017, 37(18): 5238-5247.
- [6] 张学清,梁军,张熙,等.基于样本熵和极端学习机的超短期风电功率组合预测模型[J].中国电机工程学报,2013,33(25):33-40.  
ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine [J]. Proceedings of the CSEE, 2013, 33(25): 33-40.
- [7] 王振浩,王翀,成龙,等.基于集合经验模态分解和深度学习的光伏功率组合预测[J].高电压技术,2022,48(10):4133-4142.  
WANG Zhenhao, WANG Chong, CHENG Long, et al. Photovoltaic power combined prediction based on ensemble empirical mode decomposition and deep learning [J]. High Voltage Engineering, 2022, 48(10): 4133-4142.
- [8] 杨茂,王凯旋.基于CEEMD-DBN模型的光伏出力日前区间预测[J].高电压技术,2021,47(4):1156-1164.  
YANG Mao, WANG Kaixuan. Day-ahead interval forecasting of PV power based on CEEMD-DBN model [J]. High Voltage Engineering, 2021, 47(4): 1156-1164.
- [9] JUBAN J, FUGON L, KARINIOTAKIS G. Probabilistic short-term wind power forecasting based on kernel density estimators [C]// European Wind Energy Conference, May 7-10, 2007, Milan, Italy: 7-10.
- [10] 范磊,卫志农,李慧杰,等.基于变分模态分解和蝙蝠算法-相关向量机的短期风速区间预测[J].电力自动化设备,2017,37(1):93-100.  
FAN Lei, WEI Zhinong, LI Huijie, et al. Short-term wind speed interval prediction based on VMD and BA-RVM algorithm [J]. Electric Power Automation Equipment, 2017, 37(1): 93-100.
- [11] 王焱,汪震,黄民翔,等.基于OS-ELM和Bootstrap方法的超短期风电功率预测[J].电力系统自动化,2014,38(6):14-19.  
WANG Yan, WANG Zhen, HUANG Minxiang, et al. Ultra-short-term wind power prediction based on OS-ELM and Bootstrap method [J]. Automation of Electric Power Systems, 2014, 38(6): 14-19.
- [12] 王勃,刘纯,张俊,等.基于Monte-Carlo方法的风电功率预测不确定性估计[J].高电压技术,2015,41(10):3385-3391.  
WANG Bo, LIU Chun, ZHANG Jun, et al. Uncertainty evaluation of wind power prediction based on Monte-Carlo method [J]. High Voltage Engineering, 2015, 41(10): 3385-3391.
- [13] 殷豪,曾云,孟安波,等.基于奇异谱分析-模糊信息粒化和极限学习机的风速多步区间预测[J].电网技术,2018,42(5):1467-1474.  
YIN Hao, ZENG Yun, MENG Anbo, et al. Wind speed multi-step interval prediction based on singular spectrum analysis-fuzzy information granulation and extreme learning machine [J]. Power System Technology, 2018, 42(5): 1467-1474.
- [14] 杨茂,白玉莹.基于多位置NWP和门控循环单元的风电功率超短期预测[J].电力系统自动化,2021,45(1):177-183.  
YANG Mao, BAI Yuying. Ultra-short-term prediction of wind power based on multi-location numerical weather prediction and gated recurrent unit [J]. Automation of Electric Power Systems, 2021, 45(1): 177-183.
- [15] 朱乔木,李弘毅,王子琪,等.基于长短期记忆网络的风电场发电功率超短期预测[J].电网技术,2017,41(12):3797-3802.  
ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM [J]. Power System Technology, 2017, 41(12): 3797-3802.
- [16] 景惠甜,韩丽,高志宇.基于卷积神经网络特征提取的风电功率爬坡预测[J].电力系统自动化,2021,45(4):98-105.  
JING Huitian, HAN Li, GAO Zhiyu. Wind power ramp forecast based on feature extraction using convolutional neural network [J]. Automation of Electric Power Systems, 2021, 45(4): 98-105.
- [17] 张宇帆,艾芊,林琳,等.基于深度长短时记忆网络的区域级超短期负荷预测方法[J].电网技术,2019,43(6):1884-1892.  
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. Power System Technology, 2019, 43(6): 1884-1892.
- [18] 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.
- SHENG Siqing, JIN Hang, LIU Changrong. Short-term and mid-short-term wind power forecasting based on VMD-WSGRU [J]. Power System Technology, 2022, 46(3): 897-904.
- [19] ZHANG G, LIU H C, ZHANG J B, et al. Wind power prediction based on variational mode decomposition multi-frequency combinations[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(2): 281-288.
- [20] 茆美琴, 龚文剑, 张榴晨, 等. 基于EEMD-SVM方法的光伏电站短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 17-24.
- MAO Meiqin, GONG Wenjian, ZHANG Liuchen, et al. Short-term photovoltaic generation forecasting based on EEMD-SVM combined method [J]. Proceedings of the CSEE, 2013, 33(34): 17-24.
- [21] 殷豪, 欧祖宏, 陈德, 等. 基于二次模式分解和级联式深度学习的超短期风电功率预测[J]. 电网技术, 2020, 44(2): 445-453.
- YIN Hao, OU Zuhong, CHEN De, et al. Ultra-short-term wind power prediction based on two-layer mode decomposition and cascaded deep learning [J]. Power System Technology, 2020, 44(2): 445-453.
- [22] 陈锦鹏, 胡志坚, 陈伟楠, 等. 二次模态分解组合DBiLSTM-MLR的综合能源系统负荷预测[J]. 电力系统自动化, 2021, 45(13): 85-94.
- CHEN Jinpeng, HU Zhijian, CHEN Weinan, et al. Load prediction of integrated energy system based on combination of quadratic modal decomposition and deep bidirectional long short-term memory and multiple linear regression [J]. Automation of Electric Power Systems, 2021, 45(13): 85-94.
- [23] LIU H, TIAN H Q, LIANG X F, et al. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks [J]. Applied Energy, 2015, 157: 183-194.
- [24] 肖白, 肖志峰, 姜卓, 等. 基于降噪自编码器、奇异谱分析和长短期记忆神经网络的空间电力负荷态势感知[J]. 中国电机工程学报, 2021, 41(14): 4858-4867.
- XIAO Bai, XIAO Zhifeng, JIANG Zhuo, et al. Spatial load situation awareness based on denoising autoencoder, singular spectrum analysis and long short-term memory neural networks [J]. Proceedings of the CSEE, 2021, 41(14): 4858-4867.
- [25] 谢小瑜, 周俊煌, 张勇军, 等. 基于W-BiLSTM的可再生能源超短期发电功率预测方法[J]. 电力系统自动化, 2021, 45(8): 175-184.
- XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun, et al. W-BiLSTM based ultra-short-term generation power prediction method of renewable energy [J]. Automation of Electric Power Systems, 2021, 45(8): 175-184.
- [26] YANG B, WANG Y S, ZHAN Y D. Lithium battery state-of-charge estimation based on a Bayesian optimization bidirectional long short-term memory neural network [J]. Energies, 2022, 15(13): 4670.

肖 白(1973—),男,通信作者,博士,教授,博士生导师,主要研究方向:电力系统规划、空间电力负荷预测、多种能源互补协调发电、电价套餐设计、电能质量综合治理等。E-mail:xbxiaobai@126.com

张 博(1998—),男,硕士研究生,主要研究方向:多种能源互补协调发电。E-mail:599939246@qq.com

王辛玮(1998—),男,硕士研究生,主要研究方向:光热发电。E-mail:865853578@qq.com

(编辑 代长振)

## Short-term Wind Power Interval Prediction Based on Combined Mode Decomposition and Deep Learning

XIAO Bai, ZHANG Bo, WANG Xinwei, GAO Ningyuan

(School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China)

**Abstract:** Wind power prediction is very important for the economic dispatch of power systems with wind power. Aiming at the problem that point prediction is difficult to describe the uncertainty of wind power, a short-term wind power interval prediction method based on combined mode decomposition and deep learning is proposed. First, the original wind power sequence is decomposed into multiple modal components by using the improved complete ensemble empirical mode decomposition with adaptive noise, and the high-frequency strong non-stationary components are decomposed again by using the variational mode decomposition. On this basis, the sample entropy is used to calculate the complexity of each component and reconstruct them into trend components, oscillation components and random components. Then, the three components are input into the Bayesian optimization bidirectional long short-term memory neural network to establish their respective prediction models, and the point prediction values of the three components are obtained. The mixed kernel density estimation method is used to estimate the error distribution of the prediction results of oscillation components and random components, and the overall interval prediction results are obtained by combining the point prediction values. Finally, the actual example analysis shows that this method has higher prediction accuracy than other models.

The work is supported by National Key R&D Program of China (No. 2017YFB0902205) and Industrial Innovation Foundation of Jilin Province (No. 2019C058-7).

**Key words:** wind power prediction; long short-term memory; deep learning; interval prediction; empirical mode decomposition; kernel density estimation

