

DOI: 10.19783/j.cnki.pspc.230397

## 基于贝叶斯优化的 VMD-GRU 短期风电功率预测

刘新宇, 蒲欣雨, 李继方, 张江涛

(华北水利水电大学, 河南 郑州 450045)

**摘要:** 为提高风电功率预测精度, 提出了一种基于贝叶斯优化的变分模态分解(variational mode decomposition, VMD)和门控循环单元(gated recurrent unit, GRU)相结合的风电功率预测方法。首先使用 VMD 算法对风电功率序列进行分解, 并根据排列熵(permutation entropy, PE)的大小来确定序列分解的最佳模态数。然后将分解后得到的子序列分量与关键气象变量数据结合构成模型输入特征。使用 GRU 网络对各个子序列分量分别进行预测, 并将各个子序列分量的预测结果进行重构得到风电功率预测结果。最后采用贝叶斯优化方法对各个子序列预测模型的初始超参数进行优化。采用某风电场的风电数据对所提模型进行验证, 并与其他 6 种模型进行性能对比。结果表明, 基于贝叶斯优化的 VMD-GRU 预测模型明显优于其他模型, 具有较好的泛化能力, 能够有效提高风电功率预测精度。

**关键词:** 风电功率; 变分模态分解; 排列熵; 门控循环单元; 贝叶斯优化

### Short-term wind power prediction of a VMD-GRU based on Bayesian optimization

LIU Xinyu, PU Xinyu, LI Jifang, ZHANG Jiangtao

(North China University of Water Resources and Electric Power, Zhengzhou 450045, China)

**Abstract:** To improve the accuracy of wind power prediction, a wind power prediction method based on Bayesian optimization variational mode decomposition (VMD) and a gated recurrent unit (GRU) is proposed. First, the VMD algorithm is used to decompose the wind power sequence, and the optimal mode number of sequence decomposition is determined according to the size of permutation entropy (PE). Then, the decomposed sub-sequence components are combined with the key meteorological variable data to form the input characteristics of the model. The GRU network is used to predict each sub-sequence component separately, and the prediction results of each sub-sequence component are reconstructed to obtain the wind power prediction results. Finally, the Bayesian optimization method is used to optimize the network initial hyperparameters of each subsequent prediction model. The proposed model is evaluated on a real wind power data from a wind farm and compared with six baseline models. The results show that the VMD-GRU prediction model based on Bayesian optimization is clearly the superior model, has better generalizability, and can effectively improve the prediction accuracy of wind power.

This work is supported by the National Natural Science Foundation of China (No. U1804149).

**Key words:** wind power; variational mode decomposition; permutation entropy; gated circulation unit; Bayesian optimization

## 0 引言

力争 2030 年前实现碳达峰、2060 年前实现碳中和, 是中国经过深思熟虑做出的重大决策。可再生能源的开发和利用是实现“双碳”目标的重要途径。

**基金项目:** 国家自然科学基金项目资助(U1804149); 河南省高等学校重点科研项目资助(21A120006)

风能具有无污染、储量大、可再生等优点, 在能源供给中的比重不断提高。国家能源局公布的数据显示, 截至 2021 年底, 全国风电累计装机 3.28 亿 kW, 占全国总发电装机容量的 13.8%<sup>[1]</sup>。但是由于风电功率具有随机性和波动性的特点, 当风电并网时, 风电功率的特性会导致电网受到电流冲击, 严重时甚至会导致电网不可控。因此, 为了有效利用风能同时使风电并网稳定运行, 必须提高风电功

率预测精度<sup>[2-3]</sup>。

风电功率预测方法可划分为物理方法、统计方法和学习方法 3 类。每种方法都有各自的适用时间范围和优缺点<sup>[4]</sup>。物理方法通过数值天气预报(numerical weather prediction, NWP)方式获取风力机轮毂高度处的风速、风向、空气密度、压强等信息,并将其作为输入特征,代入风力机功率曲线得到风电功率预测值<sup>[5-6]</sup>。但是,由于物理模型建模机理过于复杂、建模信息难以收集,在短期风电功率预测中物理模型难以取得理想的预测效果。统计方法包括马尔可夫链、贝叶斯方法、时间序列分析等<sup>[7]</sup>。统计模型的建立过程比较简单,但非线性拟合能力差。虽然物理模型和统计学模型都可以对风电功率进行短期预测,但是由于二者的固有缺陷,物理模型和统计学模型在短期风电功率预测中难以取得理想的预测效果。相较物理方法和统计方法,学习方法通过大量风电数据来学习风电功率的特征,能够充分挖掘风电功率的特征,具有强大的非线性映射能力,因此能够取得较好的预测效果。

目前,常用的学习方法有支持向量机(support vector machines, SVM)<sup>[8]</sup>、误差反向传播(back propagation, BP)<sup>[9]</sup>神经网络、极限学习机(extreme learning machine, ELM)<sup>[10]</sup>等。深度学习算法是对传统学习算法的改进和发展,在风电功率预测方面已成为研究热点。与传统学习方法相比,深度学习方法在提取隐藏的自然结构和数据的固有抽象特征方面具有更好的性能<sup>[11]</sup>。常用的深度学习算法有卷积神经网络(convolutional neural networks, CNN)<sup>[12-13]</sup>、长短时记忆网络(long short-term memory, LSTM)<sup>[14-15]</sup>和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)<sup>[16]</sup>等。

由于风电功率序列一般为非平稳序列,直接对风电功率序列进行预测难以取得良好的预测效果。对风电功率时间序列进行分解,可以降低数据复杂度,进而提高风电功率预测精度。常用的分解算法有小波变换(wavelet transform, WT)<sup>[17-18]</sup>、经验模态分解(empirical mode decomposition, EMD)<sup>[19]</sup>、快速傅里叶变换(fast Fourier transform, FFT)<sup>[20]</sup>等。WT 算法不具备平移不变性,计算复杂度较高,容易出现数据边缘效应导致误差增加。FFT 算法未考虑时频的局部特性,对于非周期性信号的处理不如小波变换。EMD 算法具有较好的自适应性,但计算效率低,存在模态混叠问题。变分模态分解(variational mode decomposition, VMD)算法解决了 EMD 算法的模态混叠问题,具有良好的自适应性和可重构性,

能够更准确地将信号分解为本征模态,同时减少噪声的影响<sup>[21]</sup>。因此,本文采用 VMD 算法对风电功率时间序列进行分解。

为提高风电功率预测精度,本文提出了一种基于贝叶斯优化的 VMD-GRU 组合预测方法。首先,采用 VMD 算法对风电功率时间序列数据进行分解,根据 PE 值的大小确定序列分解的最佳模态数。其次,将分解后得到的子序列分量与关键气象数据结合构成模型输入,对每个模态分别建立门控循环单元(gated recurrent unit, GRU)预测模型。最后,利用贝叶斯优化方法对每个子序列模型的网络超参数进行优化。结果表明,本文所提方法可有效地提高风电功率预测精度。

## 1 风电功率时间序列分解

### 1.1 VMD 分解

风电功率受风速、风向、大气压强等因素的影响,一般为非平稳序列。为了提高预测精度,减小风电功率时间序列非平稳性的影响,采用 VMD 算法,将风电功率序列分解为若干个子时间序列分别进行预测。

VMD 是一种自适应、准正交的信号分解方法,可将信号  $f(t)$  分解为具有一定稀疏性质的多个模态函数  $\{u_k(t)\}_{k=1}^K$ ,  $\omega_k$  为各模态中心频率<sup>[22]</sup>。

VMD 方法的信号分解过程如下。

1) 将 VMD 分解写成有约束的优化问题。

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

式中:  $\{u_k\}$  表示  $k$  个模态分量;  $\{\omega_k\}$  表示  $k$  个分量的中心频率;  $\partial_t$  表示对  $t$  求偏导;  $\delta(t)$  表示狄拉克函数; “\*” 表示卷积。

2) 引入二次罚函数项和拉格朗日乘子项将有约束最优化问题转换为无约束最优化问题。

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

$$\alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \left\| f(t) - \sum_k u_k(t) \right\|^2 + \left( \lambda(t), f(t) - \sum_k u_k(t) \right) \quad (2)$$

式中:  $L(\cdot)$  为增广拉格朗日函数;  $\lambda$  为拉格朗日乘数;  $\alpha$  为惩罚参数。

3) 用交替方向乘子法求解。 $u_k$  和  $\omega_k$  的更新公式为

$$\hat{u}_k^{n_1+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega) / 2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n_1+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

式中： $n_1$  表示迭代次数； $\hat{u}_k^{n_1+1}(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$  分别是  $u_k^{n_1+1}(t)$ 、 $f(t)$ 、 $u_k(t)$ 、 $\lambda(t)$  的傅里叶变换。

### 1.2 排列熵

排列熵是用来衡量时间序列的复杂程度的一种指标。它将时间序列的数值按照大小进行排序并转换为排列序列，然后计算排列序列的熵值<sup>[23]</sup>。本文采用排列熵指标来评价 VMD 分解后子时间序列的复杂程度。

排列熵的计算过程如下：

1) 假设时间序列的长度为  $L$ ，将原序列  $u(1)$ 、 $u(2)$ 、 $\dots$ 、 $u(L)$  重构，新的子序列以  $u^*(i)$  表示，即

$$u^*(i) = [u(i), u(i + \tau), \dots, u(i + (m-1)\tau)] \quad (5)$$

式中： $m$  为嵌入维度； $\tau$  为时间延迟。

2) 对  $u^*(i)$  中的每个元素按递增方式排序，即

$$u^*(i) = [u(i + (q_1 - 1)\tau) \leq u(i + (q_2 - 1)\tau) \leq \dots \leq u(i + (q_m - 1)\tau)] \quad (6)$$

式中， $q_i$  表示被排列之前的位置， $i = 1, 2, \dots, m$ 。因此， $u^*(i)$  映射为  $(q_1, q_2, \dots, q_m)$ ，共有  $m!$  种排列方式。

3) 经上述操作后，每一行  $u^*(i)$  出现的频率用  $P_1, P_2, \dots, P_S$  表示，其中  $S \leq m!$ 。时间序列  $u(1)$ 、 $u(2)$ 、 $\dots$ 、 $u(L)$  的排列熵为

$$H_{PE}(m) = -\sum_{q=1}^S P_q \ln P_q \quad (7)$$

实验表明，排列熵的值越小，它所对应的时间序列越规则，排列熵的值越大，它所对应的时间序列越复杂。

本文对不同 VMD 分解数的子序列求和，得到对应的时间序列，然后计算该时间序列的排列熵。为了防止 VMD 分解出现过分解和欠分解，VMD 的最大分解数和最小分解数分别设定为 12 和 5<sup>[14]</sup>。

由表 1 可以看出，VMD 分解数为 5 时，对应的 PE 最小值的数量最多。因此，为了防止 VMD 过分解和欠分解，保证每个月进行较好的 VMD 分解，本文选取 VMD 最佳分解数为 5。原始时间序列的分解结果为 VMD1、VMD2、VMD3、VMD4、VMD5，其中 VMD1 包含原始时间序列的主要特征。

表 1 2020 年各月份不同 VMD 分解数 PE 值

Table 1 PE values of different VMD decomposition numbers in each month of 2020

月份	VMD 分解数							
	5	6	7	8	9	10	11	12
1	<b>0.740</b>	0.922	0.901	0.895	0.901	0.911	0.886	0.886
2	<b>0.806</b>	0.954	0.917	0.934	0.918	0.928	0.935	0.935
3	<b>0.740</b>	0.911	0.921	0.913	0.896	0.883	0.872	0.891
4	<b>0.852</b>	0.915	0.883	0.890	0.911	0.901	0.890	0.889
5	0.884	<b>0.792</b>	0.796	0.906	0.894	0.874	0.873	0.903
6	0.919	0.924	0.820	<b>0.816</b>	0.890	0.874	0.899	0.911
7	<b>0.770</b>	0.798	0.895	0.896	0.913	0.882	0.872	0.869
8	<b>0.756</b>	0.825	0.928	0.916	0.927	0.866	0.901	0.907
9	<b>0.732</b>	0.785	0.836	0.833	0.909	0.904	0.902	0.899
10	0.883	0.832	<b>0.831</b>	0.874	0.905	0.884	0.923	0.915
11	<b>0.725</b>	0.764	0.862	0.907	0.867	0.889	0.881	0.882
12	<b>0.796</b>	0.822	0.843	0.853	0.917	0.887	0.876	0.894

## 2 门控循环单元

针对神经网络在计算梯度的过程中因矩阵连乘而造成的梯度消失和梯度爆炸的问题，学术界提出了许多方法来解决这类问题<sup>[24]</sup>。长短期记忆网络是较早解决这类问题的方法，但其模型结构比 GRU 模型复杂，具有 3 种控制门<sup>[25-26]</sup>。GRU 网络可以提供与 LSTM 网络同等的效果，且结构更加简单<sup>[27-28]</sup>。为了简化模型结构，提高计算速度，本文采用具有两种控制门的 GRU 网络。GRU 网络结构图如图 1 所示。

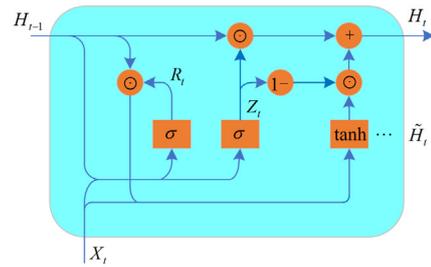


图 1 GRU 网络结构图

Fig. 1 GRU network structure diagram

从图 1 可知，GRU 网络主要包含了重置门  $R_t$ 、更新门  $Z_t$ 、候选隐状态  $\tilde{H}_t$  和隐状态  $H_t$ 。重置门和更新门的输入是当前时间步的输入  $X_t$  和上一时间步的隐状态  $H_{t-1}$ 。重置门和更新门的计算方式为

$$R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r) \quad (8)$$

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z) \quad (9)$$

式中:  $\sigma$  为 Sigmoid 激活函数; 给定时间步  $t$ , 输入  $X_t \in \mathbb{R}^{n \times d}$ ,  $n$  为样本个数,  $d$  为特征个数;  $H_{t-1} \in \mathbb{R}^{n \times h}$ ,  $h$  为隐藏单元个数;  $W_{xv}, W_{xz} \in \mathbb{R}^{d \times h}$  和  $W_{hv}$ ,  $W_{hz} \in \mathbb{R}^{h \times h}$  为权重参数;  $b_v, b_z \in \mathbb{R}^{1 \times h}$  为偏置参数。

候选隐状态的计算中, 重置门  $R_t$  和上一时间步的隐状态  $H_{t-1}$  按元素乘积。如果重置门  $R_t$  中所有元素接近 1, 表示保留上一时间步的隐藏状态。如果重置门  $R_t$  中所有元素接近 0, 表示丢弃上一时间步的隐藏状态。候选隐状态的计算公式为

$$\tilde{H}_t = \tanh(X_t W_{xh} + (R_t \odot H_{t-1}) W_{hh} + b_h) \quad (10)$$

式中:  $W_{xh} \in \mathbb{R}^{d \times h}$  和  $W_{hh} \in \mathbb{R}^{h \times h}$  为权重参数;  $b_h \in \mathbb{R}^{1 \times h}$  为偏置参数; 符号 “ $\odot$ ” 为按元素乘积运算符。候选隐状态的激活函数选择  $\tanh$  函数, 以保证候选隐状态的值在  $-1 \sim 1$  之间。

时间步  $t$  时的隐状态  $H_t \in \mathbb{R}^{n \times h}$  的计算是当前时间步的更新门  $Z_t$  对上一时间步的隐状态  $H_{t-1}$  和当前时间步的候选隐状态  $\tilde{H}_t$  按元素的凸组合实现。因此, 门控循环单元的最终更新公式为

$$H_t = Z_t \odot H_{t-1} + (1 - Z_t) \odot \tilde{H}_t \quad (11)$$

门控循环单元中, 重置门有助于捕捉时间序列中短期依赖关系, 更新门有助于捕捉时间序列中长期依赖关系。门控循环单元通过引入重置门和更新门, 有效地解决了传统循环神经网络单元中存在的长期依赖问题, 使得循环神经网络在处理序列数据时具有更强的表达能力和适用性。

### 3 基于贝叶斯优化的 VMD-GRU 预测模型

#### 3.1 贝叶斯优化理论

贝叶斯优化是一种在黑箱函数优化中广泛应用的方法。其主要思想是在已知先验分布和数据的情况下, 通过不断更新后验分布来寻找最优解<sup>[29]</sup>。

贝叶斯优化算法核心由高斯过程回归和采集函数两部分组成。

##### 1) 高斯过程回归

高斯过程回归是一种基于概率的非参数回归方法。其核心思想是假设待预测的目标函数  $g$  服从一个高斯分布, 然后利用已有数据对该分布的均值和方差进行估计<sup>[30]</sup>。高斯过程回归预测公式为

$$\begin{cases} \mu(a^*) = c^{*T} (C + \sigma_n^2 I)^{-1} b \\ c_{ov}(a^*) = c - c^{*T} (C + \sigma_n^2 I)^{-1} c^* \end{cases} \quad (12)$$

式中:  $a^*$  表示目标函数预测值对应的输入点;  $\mu(a^*)$  表示函数在  $a^*$  处的均值;  $c_{ov}(a^*)$  表示函数在  $a^*$  处的协方差;  $c$  为测试点自身的协方差;  $c^*$  为测试点与

训练数据点的协方差向量;  $C$  为训练数据点之间的协方差矩阵;  $\sigma_n^2$  为高斯噪声的方差;  $I$  为单位矩阵;  $b$  为训练数据点的目标值向量。

##### 2) 采集函数

本文基于高斯过程回归构建采样函数。使用高斯过程回归预测当前最有可能的函数取值, 并计算每个采样点的概率密度函数, 根据该概率密度函数进行采样, 得到一个新的点作为下一次优化的输入。采集函数公式为

$$a_{t+1} = \operatorname{argmax}_{a \in A} E_1(a) \quad (13)$$

$$E_1(a) = \int_{-\infty}^{g_{\min}} (g(a) - g_{\min}) p(g|D) dg \quad (14)$$

式中:  $a$  表示采样点;  $a_{t+1}$  表示下一个新的采样点;  $A$  表示搜索空间;  $E_1(\cdot)$  为期望提升函数;  $g_{\min}$  为当前最优解的取值;  $p(g|D)$  表示在已知数据  $D$  的情况下函数  $g$  的概率分布。

#### 3.2 预测模型构建

为了提高风电功率预测精度, 采用 GRU 模型充分挖掘历史风电功率之间的时间特征, 同时考虑到关键气象因素对风电功率的影响, 将关键气象因素与历史风电功率数据结合送入 GRU 模型。为减小风电功率随机波动性对风电功率预测精度的影响, 采用 VMD 算法将风电功率分解为若干个较平稳的子序列。为了进一步提高风电功率预测精度, 同时减少参数调优时间, 采用贝叶斯优化算法对各个子序列模型的网络超参数分别进行优化。基于贝叶斯优化的 VMD-GRU 短期风电功率预测流程图如图 2 所示。组合预测模型的构建步骤如下。

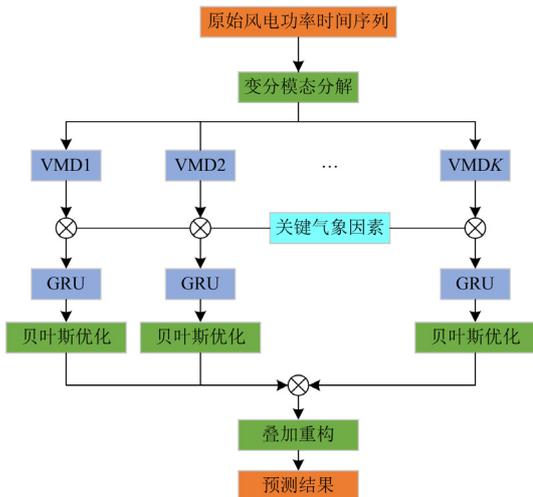


图 2 基于贝叶斯优化的 VMD-GRU 短期风电功率预测流程图

Fig. 2 Flow chart of VMD-GRU wind power prediction based on Bayesian optimization

- 1) 采用 VMD 算法将原始风电功率时间序列分解为若干个子序列分量;
- 2) 将分解后得到的子序列分量和关键气象因素结合构成模型输入;
- 3) 针对每个子序列分别构建对应的 GRU 预测模型;
- 4) 采用贝叶斯优化算法优化每个子序列 GRU 预测模型的网络超参数;
- 5) 将各个子序列模型的预测值叠加重构, 得到风电功率预测结果。

### 3.3 评价指标

本文选取均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数  $R^2$  来评价预测模型的性能。决定系数  $R^2$  的取值范围是 0~1,  $R^2$  越接近 1, 表明模型越能够较好地拟合数据的变化趋势。

各评价指标的计算公式为

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{o=1}^N (y_o - \hat{y}_o)^2} \quad (15)$$

$$e_{MAE} = \frac{1}{N} \sum_{o=1}^N |y_o - \hat{y}_o| \quad (16)$$

$$R^2 = 1 - \frac{\sum_{o=1}^N (\hat{y}_o - y_o)^2}{\sum_{o=1}^N (\bar{y} - y_o)^2} \quad (17)$$

式中:  $e_{RMSE}$  和  $e_{MAE}$  分别为均方根误差和平均绝对误差;  $N$  为总的样本个数;  $y_o$  为采样点  $o$  的实际值;  $\hat{y}_o$  为采样点  $o$  的预测值;  $\bar{y}$  为  $y_o$  的均值。

## 4 实例验证

为了验证所提模型的有效性和可行性, 选取了某风电场 2020 年的风电数据进行实例验证。风电数据采样时间间隔为 15 min, 选取每月最后 3 天的数据作为测试集, 其他数据作为训练集和验证集, 验证集划分比例为 20%。

### 4.1 基于 GRU 模型的预测结果分析

为了验证本文选取的 GRU 预测模型的短期风电功率预测效果, 采用 LSTM 和 BiLSTM 模型进行对比分析。2020 年每月各个模型的评价指标如图 3 所示。

从图 3 可以直观地看出, 除 5 月、7 月和 11 月外, GRU 模型的 RMSE 和 MAE 均低于 BiLSTM 和 LSTM 模型, 表明 GRU 模型的预测能力较强。因此, 本文选取了 GRU 模型进行短期风电功率预测。针对 5 月、7 月和 11 月 GRU 模型的部分评价

指标较差的问题, 分析原因可能是 5 月、7 月和 11 月数据的噪声较大, 因此, 下面采用 VMD 算法对原始风电功率数据进行降噪优化。

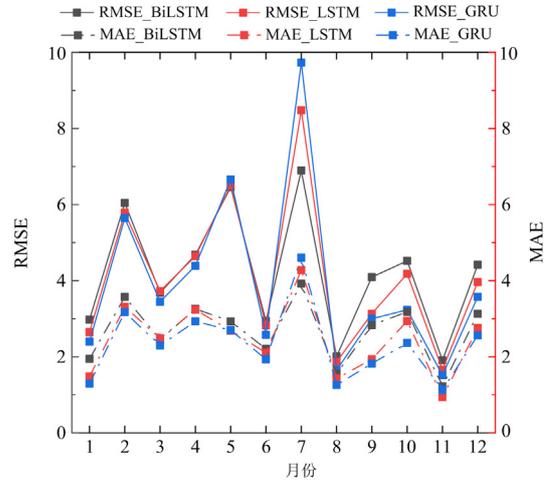


图 3 2020 年 BiLSTM、LSTM、GRU 模型评价指标  
Fig. 3 Evaluation indicators of BiLSTM, LSTM, GRU model in 2020

### 4.2 基于 VMD-GRU 模型的预测结果分析

为了进一步提高短期风电功率预测精度, 本文采用 VMD 算法对原始风电功率数据进行了分解, 降低了原始风电功率的复杂度和噪声。针对每个子序列分量分别建立了 GRU 预测模型, 将各个子序列预测模型的结果叠加重构, 得到风电功率预测结果。为验证 VMD-GRU 预测模型的预测效果, 采用了 VMD-BiLSTM 和 VMD-LSTM 预测模型进行对比分析。各个模型在不同月份的评价指标如图 4 所示。

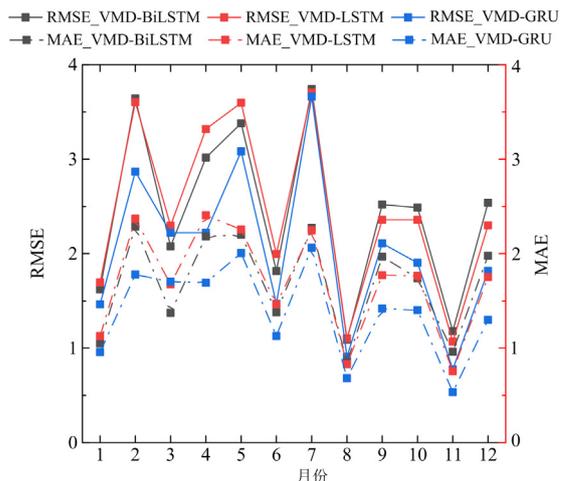


图 4 VMD-BiLSTM、VMD-LSTM、VMD-GRU 模型评价指标  
Fig. 4 Evaluation indicators of VMD-BiLSTM, VMD-LSTM, VMD-GRU model

从图 4 中可以看出, 除 3 月外, VMD-GRU 模型的 RMSE 和 MAE 指标均低于另外两种模型, 表明 VMD-GRU 模型的预测效果较好。从图 4 中还可看出, 5 月和 7 月 VMD-GRU 模型的评价指标优于其他模型, 侧面验证了 VMD 算法降噪优化有助于提高风电功率预测精度。因此, 本文选取 VMD-GRU 模型进行短期风电功率预测。

#### 4.3 基于贝叶斯优化的 VMD-GRU 模型的预测结果分析

为了进一步提高短期风电功率预测精度, 寻求最优超参数, 减少超参数整定时间, 本文采用贝叶斯优化理论优化每个子序列模型的超参数。贝叶斯优化前后 VMD-GRU 预测模型的评价指标如图 5 所示。

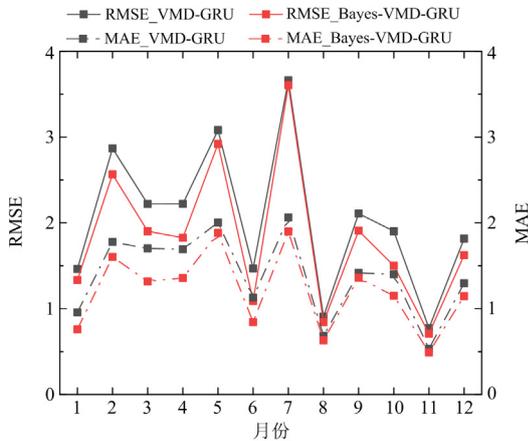


图 5 贝叶斯优化前后 VMD-GRU 模型评价指标

Fig. 5 Evaluation indexes of VMD-GRU model before and after Bayesian optimization

从图 5 可以看出, 采用贝叶斯优化算法对 VMD-GRU 组合预测模型的超参数进行优化后, 各个月份模型的 RMSE 和 MAE 指标均减少, 表明采用贝叶斯优化算法可以寻找到模型的较优超参数, 从而提高短期风电功率预测精度。

基于贝叶斯优化的 VMD-GRU 模型及其他对比模型的预测结果如图 6 所示。相应的评价指标如表 2 所示。

从图 6 可以看出, 各模型的预测结果均接近真实值, 均可以较好地拟合真实值的变化趋势, 表明深度学习模型在短期风电功率预测方面具有良好的性能。其中, 基于贝叶斯优化的 VMD-GRU 模型的预测值曲线最为平滑, 能够较好地跟踪真实值曲线。

从表 2 可以看出, 相比于 GRU 模型, VMD-GRU 模型的 RMSE、MAE 分别降低了 35.55%、25.86%,  $R^2$  提升了 1.96%。其他两种模型采用 VMD 算法后,

性能评价指标均得到改善。表明采用 VMD 算法对风电功率数据进行分解, 可显著提高短期风电功率预测精度。

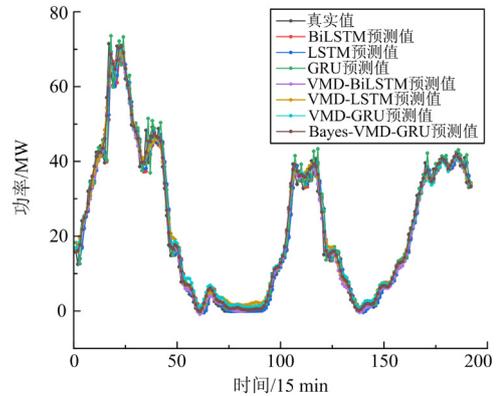


图 6 2020 年 3 月各模型预测结果

Fig. 6 Forecast results of each model in March 2020

表 2 2020 年 3 月各模型评价指标

Table 2 Evaluation indicators of each model in March 2020

模型	RMSE	MAE	$R^2$
BiLSTM	3.685	2.449	0.964
LSTM	3.726	2.482	0.963
GRU	3.446	2.297	0.968
VMD-BiLSTM	2.077	1.374	0.988
VMD-LSTM	2.296	1.676	0.986
VMD-GRU	2.221	1.703	0.987
Bayes-VMD-GRU	1.903	1.319	0.990

相比于 VMD-GRU 模型, 基于贝叶斯优化的 VMD-GRU 模型的 RMSE、MAE 和  $R^2$  分别提升了 14.32%、22.55% 和 0.30%。表明采用贝叶斯优化算法可以寻找到 VMD-GRU 组合预测模型的较优超参数, 进而提高短期风电功率的预测精度。从表 2 可以看出, Bayes-VMD-GRU 模型的各项评价指标均优于其他模型, 表明本文所提算法可有效提高短期风电功率预测精度。

## 5 结论

为提高风电功率预测精度, 本文提出了一种基于贝叶斯优化的 VMD-GRU 组合预测模型。通过对某风电场的风电数据进行实例分析, 得到以下结论:

- 1) 采用多组风电数据进行预测, GRU 模型在多组风电功率数据的预测效果整体优于 LSTM、BiLSTM 模型;
- 2) 采用 VMD 算法对原始风电功率序列进行分解, 可以降低其复杂度和非平稳性, 进而提高短期风电功率预测精度;
- 3) 采用贝叶斯优化算法对 VMD-GRU 组合模

型的网络超参数进行优化,可以寻找到较优超参数,进而提高短期风电功率预测精度。

本文所提的基于贝叶斯优化的 VMD-GRU 组合预测模型,能够较好地拟合风电功率变化趋势,提高了短期风电功率预测精度,可以为电网优化调度提供更精确的风电功率数据。

### 参考文献

- [1] 国家能源局. 国家能源局 2022 年一季度网上新闻发布会文字实录[EB/OL]. [2022-01-28]. [http://www.nea.gov.cn/2022/01/28/c\\_1310445390.htm](http://www.nea.gov.cn/2022/01/28/c_1310445390.htm).  
National Energy Administration. transcript of the online press conference of the national energy administration in the first quarter of 2022[EB/OL]. [2022-01-28]. [http://www.nea.gov.cn/2022/01/28/c\\_1310445390.htm](http://www.nea.gov.cn/2022/01/28/c_1310445390.htm).
- [2] 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.  
SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.
- [3] 朱显辉, 于越, 师楠, 等. BP 神经网络的分层优化研究及其在风电功率预测中的应用[J]. 高压电器, 2022, 58(2): 158-163, 170.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP neural network and its application in wind power prediction[J]. High Voltage Apparatus, 2022, 58(2): 158-163, 170.
- [4] 武煜昊, 王永生, 徐昊, 等. 风电输出功率预测技术研究综述[J]. 计算机科学与探索, 2022, 16(12): 2653-2677.  
WU Yuhao, WANG Yongsheng, XU Hao, et al. Survey of wind power output power forecasting technology[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(12): 2653-2677.
- [5] 卢继平, 曾燕婷, 喻华, 等. 基于改进 AWNN 的风电功率超短期多步预测[J]. 太阳能学报, 2021, 42(1): 166-173.  
LU Jiping, ZENG Yanting, YU Hua, et al. Ultra-short-term wind power multi-step forecasting based on improved AWNN[J]. Acta Energetica Solaris Sinica, 2021, 42(1): 166-173.
- [6] 韦权, 汤占军. 基于 SSA-VMD-SE-KELM 结合蒙特卡洛法的风电功率区间预测[J]. 智慧电力, 2022, 50(9): 59-66.  
WEI Quan, TANG Zhanjun. Wind power range prediction based on SSA-VMD-SE-KELM combined with Monte Carlo method[J]. Smart Power, 2022, 50(9): 59-66.
- [7] 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.  
TANG Xinzi, GU Nengwei, HUANG Xuanqing, et al. Progress on short term wind power forecasting technology[J]. Journal of Mechanical Engineering, 2022, 58(12): 213-236.
- [8] 王涛, 高靖, 王优胤, 等. 基于改进经验模态分解和支持向量机的风电功率预测研究[J]. 电测与仪表, 2021, 58(6): 49-54.  
WANG Tao, GAO Jing, WANG Youyin, et al. Wind power prediction based on improved empirical mode decomposition and support vector machine[J]. Electrical Measurement & Instrumentation, 2021, 58(6): 49-54.
- [9] 贾德香, 吕干云, 林芬, 等. 基于 SAPSO-BP 和分位数回归的光伏功率区间预测[J]. 电力系统保护与控制, 2021, 49(10): 20-26.  
JIA Dexiang, LÜ Ganyun, LIN Fen, et al. Photovoltaic power interval prediction based on SAPSO-BP and quantile regression[J]. Power System Protection and Control, 2021, 49(10): 20-26.
- [10] 刘栋, 魏霞, 王维庆, 等. 基于 SSA-ELM 的短期风电功率预测[J]. 智慧电力, 2021, 49(6): 53-59, 123.  
LIU Dong, WEI Xia, WANG Weiqing, et al. Short-term wind power prediction based on SSA-ELM[J]. Smart Power, 2021, 49(6): 53-59, 123.
- [11] 刘攀龙, 张宏立, 王聪, 等. 基于序列到序列和注意力机制的超短期风速预测[J]. 太阳能学报, 2021, 42(9): 286-294.  
LIU Bolong, ZHANG Hongli, WANG Cong, et al. Ultra-short-term wind speed prediction based on sequence-to-sequence and attention mechanism[J]. Acta Energetica Solaris Sinica, 2021, 42(9): 286-294.
- [12] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的 CNN-LSTM 短期电价预测[J]. 电力系统保护与控制, 2022, 50(17): 125-132.  
JI Xingquan, ZENG Ruomei, ZHANG Yumin, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection and Control, 2022, 50(17): 125-132.
- [13] 樊江川, 于昊正, 刘慧婷, 等. 基于多分支门控残差卷积神经网络的短期电力负荷预测[J]. 中国电力, 2022, 55(11): 155-162, 174.  
FAN Jiangchuan, YU Haozheng, LIU Huiting, et al. Short-term load forecasting based on multi-branch residual gated convolution neural network[J]. Electric Power, 2022, 55(11): 155-162, 174.
- [14] LÜ Lingling, WU Zongyu, ZHANG Jinhua, et al. A VMD and LSTM based hybrid model of load forecasting for power grid security[J]. IEEE Transactions on Industrial Informatics, 2021, 18(9): 6474-6482.
- [15] WU Kailang, GU Jie, MENG Lu, et al. An explainable framework for load forecasting of a regional integrated energy system based on coupled features and multi-task

- learning[J]. Protection and Control of Modern Power Systems, 2022, 7(2): 349-362.
- [16] 吕大青, 杨欢红, 杜浩良, 等. 基于小波 KPCA 与 Bi-LSTM 的特高压换流站测控装置健康评估和预测[J]. 电力系统保护与控制, 2022, 50(19): 80-87.  
LÜ Daqing, YANG Huanhong, DU Haoliang, et al. Health status assessment and prediction of operational condition of a measurement and control device in a UHV converter station based on KPCA and Bi-LSTM[J]. Power System Protection and Control, 2022, 50(19): 80-87.
- [17] LIU Y, GUAN L, HOU C, et al. Wind power short-term prediction based on LSTM and discrete wavelet transform[J]. Applied Sciences, 2019, 9(6): 1108.
- [18] 崔昊杨, 孙昊宇, 杨程, 等. 计及空间相关性的轻量级风电功率预测方法[J]. 智慧电力, 2022, 50(8): 7-13, 117.  
CUI Haoyang, SUN Haoyu, YANG Cheng, et al. Lightweight wind power prediction method considering spatial correlation[J]. Smart Power, 2022, 50(8): 7-13, 117.
- [19] 杨德州, 刘嘉明, 宋汶秦, 等. 基于改进型自适应白噪声完备集成经验模态分解的工业用户负荷预测方法[J]. 电力系统保护与控制, 2022, 50(4): 36-43.  
YANG Dezhou, LIU Jiaming, SONG Wenqin, et al. A load forecasting method for industrial customers based on the ICEEMDAN algorithm[J]. Power System Protection and Control, 2022, 50(4): 36-43.
- [20] 魏震波, 余雷. 基于 FFT, DC-HC 及 LSTM 的短期负荷预测方法[J]. 智慧电力, 2022, 50(3): 37-43.  
WEI Zhenbo, YU Lei. Short-term load forecasting method based on FFT, DC-HC and LSTM[J]. Smart Power, 2022, 50(3): 37-43.
- [21] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [22] 王维高, 魏云冰, 滕旭东. 基于 VMD-SSA-LSSVM 的短期风电预测[J]. 太阳能学报, 2023, 44(3): 204-211.  
WANG Weigao, WEI Yunbing, TENG Xudong. Short-term wind power forecasting based on VMD-SSA-LSSVM[J]. Acta Energetica Solaris Sinica, 2023, 44(3): 204-211.
- [23] 武新章, 梁祥宇, 朱虹谕, 等. 基于 CEEMDAN-GRA-PCC-ATCN 的短期风电功率预测[J]. 山东大学学报(工学版), 2022, 52(6): 146-156.  
WU Xinzhang, LIANG Xiangyu, ZHU Hongyu, et al. Short-term wind power prediction based on CEEMDAN-GRA-PCC-ATCN[J]. Journal of Shandong University (Engineering Science), 2022, 52(6): 146-156.
- [24] SHAHID F, ZAMEER A, MUNEEB M. A novel genetic LSTM model for wind power forecast[J]. Energy, 2021, 223.
- [25] 陈峰, 余轶, 徐敬友, 等. 基于 Bayes-LSTM 网络的风电出力预测方法[J]. 电力系统保护与控制, 2023, 51(6): 170-178.  
CHEN Feng, YU Yi, XU Jingyou, et al. Prediction method of wind power output based on a Bayes-LSTM network[J]. Power System Protection and Control, 2023, 51(6): 170-178.
- [26] 苏向敬, 周汶鑫, 李超杰, 等. 基于双重注意力 LSTM 神经网络的可解释海上风电出力预测[J]. 电力系统自动化, 2022, 46(7): 141-151.  
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on long short-term memory neural network with dual-stage attention[J]. Automation of Electric Power Systems, 2022, 46(7): 141-151.
- [27] 杨国清, 刘世林, 王德意, 等. 基于 Attention-GRU 风速修正和 Stacking 的短期风电功率预测[J]. 太阳能学报, 2022, 43(12): 273-281.  
YANG Guoqing, LIU Shilin, WANG Deyi, et al. Short-term wind power forecasting based on Attention-GRU wind speed correction and stacking[J]. Acta Energetica Solaris Sinica, 2022, 43(12): 273-281.
- [28] 成润坤, 岳赛雅, 张国维, 等. 双碳及能源安全背景下中国电煤月度需求组合预测[J]. 智慧电力, 2022, 50(9): 1-7.  
CHENG Runkun, YUE Saiya, ZHANG Guowei, et al. Combination forecasting of monthly thermal coal demand in china under carbon peak, carbon neutrality and energy security[J]. Smart Power, 2022, 50(9): 1-7.
- [29] WANG G, JIA R, LIU J H, et al. A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning[J]. Renewable Energy, 2020, 145: 2426-2434.
- [30] 季廷炜, 莫邵昌, 谢芳芳, 等. 基于高斯过程回归的机翼/短舱一体化气动优化[J]. 浙江大学学报(工学版), 2023, 57(3): 632-642.  
JI Tingwei, MO Shaochang, XIE Fangfang, et al. Integrated aerodynamic optimization of wing/nacelle based on Gaussian process regression[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(3): 632-642.

收稿日期: 2023-04-12; 修回日期: 2023-06-15

作者简介:

刘新宇(1976—), 男, 通信作者, 博士, 教授, 研究方向为复杂建模及其智能控制、新能源发电与智能电网等; E-mail: lxy@ncwu.edu.cn

蒲欣雨(1999—), 男, 硕士研究生, 研究方向为新能源发电与风电功率预测; E-mail: 3136531791@qq.com

李继方(1971—), 男, 博士, 教授, 研究方向为电力电子与电力传动、智能电网、新能源发电与变换。E-mail: ljf538@163.com

(编辑 周金梅)