

DOI: 10.19666/j.rlfed.202312189

# 基于 VMD-ISSA-GRU 组合模型的短期 风电功率预测

王 辉<sup>1</sup>, 邹智超<sup>1</sup>, 李 欣<sup>2</sup>, 吴作辉<sup>2</sup>, 周珂锐<sup>2</sup>

(1.三峡大学电气与新能源学院, 湖北 宜昌 443002;

2.智慧能源技术湖北省工程研究中心(三峡大学), 湖北 宜昌 443002)

[摘 要] 为解决风速不确定性和波动性造成风电功率预测精度不高的问题, 提出一种基于变分模态分解(VMD)、改进麻雀搜索算法(ISSA)和门控循环神经网络(GRU)的VMD-ISSA-GRU组合模型。首先, 利用中心频率法确定采用VMD分解后的模态分量个数, 这样有效避免了过分解或者分解不充分。其次引入混沌映射、非线性递减权重以及一个突变策略来改进麻雀搜索算法, 用于优化门控循环神经网络, 然后对分解得到的各个子序列建立ISSA-GRU预测模型, 最后叠加每个子序列的预测值得到最终的预测值。将该模型用于实际风电功率预测, 实验结果表明: VMD-ISSA-GRU组合模型的平均绝对误差、平均绝对百分比误差、均方根误差分别为1.211 8 MW、1.890 0及1.591 6 MW; 相较于传统的GRU、长短时记忆(LSTM)神经网络、BiLSTM(Bi-directional LSTM)神经网络模型以及其他组合模型在预测精度上都有明显的提升, 能很好地解决风电功率预测精度不高的问题

[关 键 词] 风电功率预测; 变分模态分解; 改进麻雀搜索算法; 门控循环神经网络; 超参数

[引用本文格式] 王辉, 邹智超, 李欣, 等. 基于VMD-ISSA-GRU组合模型的短期风电功率预测[J]. 热力发电, 2024, 53(5): 122-131. WANG Hui, ZOU Zhichao, LI Xin, et al. Short-term wind power prediction based on VMD-ISSA-GRU comprehensive model[J]. Thermal Power Generation, 2024, 53(5): 122-131.

## Short-term wind power prediction based on VMD-ISSA-GRU comprehensive model

WANG Hui<sup>1</sup>, ZOU Zhichao<sup>1</sup>, LI Xin<sup>2</sup>, WU Zuohui<sup>2</sup>, ZHOU Kerui<sup>2</sup>

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

2. Hubei Engineering Research Center of Smart Energy Technology (Three Gorges University), Yichang 443002, China)

**Abstract:** In order to solve the problem of low accuracy of wind power prediction caused by wind speed uncertainty and volatility, this paper proposes a VMD-ISSA-GRU combination model based on variational mode decomposition (VMD), improved sparrow search algorithm (ISSA) and gated recurrent neural network (GRU). Firstly, the center frequency method is used to determine the number of modal components after VMD decomposition, which can effectively avoid over-decomposition or insufficient decomposition. Then, chaotic mapping, nonlinear decreasing weights and a mutation strategy are introduced to improve the sparrow search algorithm to optimize the gated recurrent neural network, and then an ISSA-GRU prediction model is established for each decomposed subsequence. Finally, the predicted value of each subseries is superimposed and the final predicted value is obtained. The experimental results show that, the mean absolute error, mean absolute percentage error and root mean square error of the VMD-ISSA-GRU model are 1.211 8, 1.890 0 and 1.591 6 MW, respectively. Compared with the conventional GRU, long short-term memory (LSTM) neural network, Bi-directional LSTM (BiLSTM) neural network model and other combination models, the prediction accuracy has been significantly improved, which can solve the problem of low prediction accuracy of wind power.

收稿日期: 2023-12-05

基金项目: 国家自然科学基金项目(52107107)

Supported by: National Natural Science Foundation of China (52107107)

第一作者简介: 王辉(1969), 男, 教授, 硕士, 主要研究方向为新能源微电网运行优化与控制, wanghui@ctgu.edu.cn.

通信作者简介: 邹智超(2000), 男, 硕士研究生, 主要研究方向为基于深度学习的目标检测、预测, 1161754021@qq.com.

**Key words:** wind power prediction; variational mode decomposition; improved sparrow search algorithm; gated recurrent neural network; hyperparameter

随着全球对环境保护意识的提高,风电作为一种清洁能源得到广泛的应用<sup>[1]</sup>。然而,由于风资源的不稳定性,风力发电量也有一定的不确定性,这也给风电并网以及电力调度与消纳带来挑战<sup>[2]</sup>。在这种情况下,风电功率预测技术可以帮助平衡系统电力供应和负荷需求之间的关系,从而保障系统安全稳定运行。因此,风电功率的准确预测具有重要实用价值<sup>[3]</sup>。

当今,由于不同的数据来源,风电功率的预测方法可分为物理学方法和统计学习方法2种<sup>[4]</sup>。统计学习方法就是利用某个风电场的历史风电功率数据及其周边风电场数据构建一个统计学习模型。另外,在短期风电功率预测中,数据挖掘技术逐渐用于提高预测的精度<sup>[5]</sup>。不过,每个模型都各有优劣,需要合理地组合各个模型,充分发挥各个模型的优势,因此如何组合各个模型以达到更高的预测精度也成为当今的研究热点之一<sup>[6]</sup>。文献[7-8]分别引入注意力机制(attention mechanism, AM)和麻雀搜索算法(sparrow search algorithm, SSA)对长短时记忆(long short-term memory, LSTM)神经网络模型进行优化,结果表明引入AM和SSA确实可以提高模型性能以及预测精度,但是也可能会出现梯度消失或梯度爆炸等问题,且传统的优化算法可能存在种群初始化质量不高、位置更新不佳等问题,因此需要使用一些数据处理方法或其他特殊的LSTM神经网络结构模型,并使用一些策略来改进优化。文献[9]利用误差倒数法对LSTM神经网络和XGboost(extreme gradient boosting)的预测数据进行加权构建组合预测模型,该组合模型在预测精度上确实有提升,但是并没有很好地解决模型参数设置的问题。文献[10]建立了基于风速误差校正和ALO(ant lion optimizer)-LSSVM(least squares support vector machines)组合模型,很好地预测了风电场多点位的风电功率。文献[11]利用基于广义反向初始化种群和自适应调整交叉概率的骨干差分进化算法去优化LSSVM,也能提高模型的预测精度。上述2篇文献都利用了优化算法,很好地解决了最小二乘支持向量机(LSSVM)在参数选择上存在困难的问题。基于此,本文通过混沌映射初始化种群,并引入非线性递减权重和一个突变策略来

更好地更新种群中各角色的位置来改进传统SSA,使改进麻雀搜索算法(ISSA)能更好解决门控循环神经网络(GRU)参数选择困难的问题,同时GRU也能有效避免出现梯度爆炸或梯度消失等问题<sup>[12]</sup>。

同时,风速具有不确定性和波动性,直接对原始数据进行训练和预测会存在难以获取数据特征、预测精度不高等问题<sup>[13]</sup>。因此,很多用于预测的组合模型都会使用一些数据分解技术来处理原始数据,如小波分解<sup>[14]</sup>、变分模态分解以及经验模态分解(empirical mode decomposition, EMD)等技术。文献[15-17]在组合模型中引入EMD,有效降低了数据的波动性以及不平稳性,提高了预测精度,文献[18]提出一种EMD-KM-SXL以及一种基于风速预测和风电功率曲线(WPC)建模的两阶段短期风电功率模型,能很好结合环境因素预测最终的风电功率,但EMD往往存在计算复杂等问题,且常常会受到模态混叠的限制。文献[19]提出EVMD-fRCN(elastic VMD-forecasting random convolution nodes)模型,通过EVMD算法将时间序列分解成多个独立的分量,并用fRCN对于每个独立的分量进行预测,最后进行叠加。基于上述文献,本文引入VMD来解决模态混叠以及计算复杂的问题,同时VMD也能很好地处理非平稳信号和噪声,这也有利于提高预测精度<sup>[20]</sup>。

综上,本文首先利用VMD将原始数据分解为多个子序列,同时使用混沌映射、非线性递减权重以及一个突变策略来改进传统SSA,并用ISSA来优化GRU的各个参数,得到VMD-ISSA-GRU组合模型,最后将VMD分解得到的各个子序列预测值进行叠加,以此获得最终的预测结果。由实验结果可知,本文所提出的VMD-ISSA-GRU组合模型在风电功率预测精度方面相较于单一模型以及其他组合模型都有明显提升。

## 1 数据处理

### 1.1 变分模态分解

VMD是由Dragomiretskiy等人于2014年提出的一种信号分解方法<sup>[21]</sup>。它可以将一个复杂的信号分解成多个具有不同中心频率和有限带宽的本征模态函数(intrinsic mode functions, IMF)。VMD

基于变分贝叶斯理论构造一个变分问题，并且利用交替方向乘法（alternating direction method of multipliers, ADMM）来求解。VMD 的优势在于能指定模态数，避免了模态混叠和端点效应，同时保证分解结果在频域上的稀疏性。VMD 的主要参数有  $K$  值，惩罚系数  $\alpha$  和收敛容差  $\text{tol}$ ，它们对分解结果有重要的影响。首先构造变分问题，步骤如下：

### 1) 构造变分问题

经过 VMD 分解得到  $K$  个子序列，这  $K$  个子序列都是具有中心频率和有限带宽的分量，同时，要求分解得到的各个模态的带宽之和最小，其约束条件表达式为：

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\text{s.t. } \sum_{k=1}^K u_k = f(t) \quad (2)$$

式中： $\{u_k\}$  为  $K$  个模态分量； $\{\omega_k\}$  为中心频率； $\partial_t$  为梯度运算； $\delta(t)$  为狄拉克函数； $*$  为卷积运算； $f(t)$  为原始信号。

### 2) 约束问题转为非约束问题求解

求解式(1)，可以使上述约束变分问题转换为非约束问题，更方便求解，其表达式为：

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \alpha_i \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

式中： $\alpha$  为二次惩罚参数； $\lambda$  为拉格朗日乘法算子。

### 3) 求解中心频率以及各个模态分量

使用 ADMM 结合 Parseval/Plancherel、傅里叶等距变换，可以得到分解后各个子序列的中心频率和模态分量，同时寻找 Lagrange 函数的鞍点，交替巡游迭代后的  $u_k$ 、 $\omega_k$  和  $\lambda$  的表达式为：

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (5)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma(f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (6)$$

式中： $\gamma$  为噪声容忍度； $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{f}(\omega)$  以及  $\hat{\lambda}(\omega)$  分别为  $u_k^{n+1}(t)$ 、 $u_i(t)$ 、 $f(t)$  和  $\lambda(t)$  的傅里叶变换。

## 2 VMD-ISSA-GRU 组合模型

### 2.1 改进麻雀搜索算法

2020 年，薛建凯等提出了一种新型智能优化算法——麻雀搜索算法<sup>[22]</sup>，该算法根据麻雀的觅食以及反捕食行为提出，具有优化效率高以及收敛速度快的特点，但也存在初始化种群质量不高、位置更新不佳等问题。因此本文通过使用混沌映射来初始化种群<sup>[23]</sup>，并使用非线性递减权重以及一个突变策略改进原有算法对传统麻雀算法中的发现者以及加入者位置更新，使其能达到更优的效果，ISSA 流程如图 1 所示。

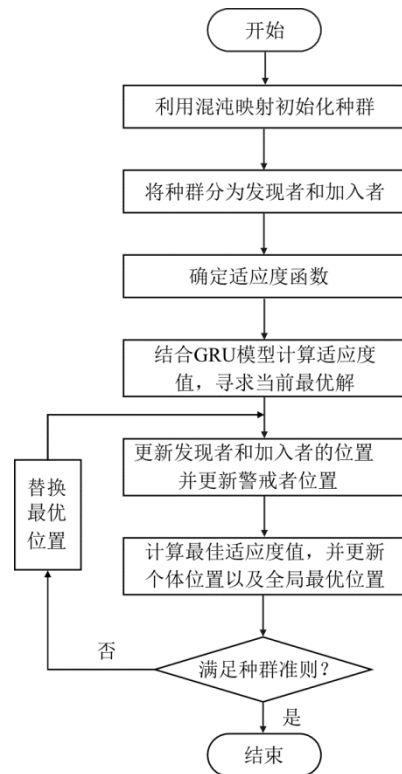


图 1 改进麻雀搜索算法流程  
Fig.1 Flowchart of the ISSA

其优化步骤如下：

#### 1) 基于混沌映射的种群初始化

首先，生成虚拟麻雀种群来模拟麻雀进行食物搜索，利用混沌映射产生的种群具有随机性、遍历性以及规律性，能提高种群质量，其表达式为：

$$x_{k+1} \begin{cases} x_k / \varphi & 0 < x_k \leq \varphi \\ (1 - x_k) / (1 - \varphi) & \varphi < x_k \leq 1 \end{cases} \quad (7)$$

式中： $x_k$  为第  $k$  只麻雀在空间中的位置； $\varphi$  为一个随机数，且  $\varphi \in (0, 1)$ 。

#### 2) 定义麻雀的适应度值

在 ISSA 中，发现者的适应度高时，更容易获

取食物，并可以为加入者提供觅食方向，所有麻雀的适应度值可以表示为：

$$F_X = \begin{bmatrix} f([x_{1,1}x_{1,2}\dots x_{1,d}]) \\ f([x_{2,1}x_{2,2}\dots x_{2,d}]) \\ \vdots \\ f([x_{n,1}x_{n,2}\dots x_{n,d}]) \end{bmatrix} \quad (8)$$

式中： $f$ 为适应度值。

3) 基于非线性递减权重更新发现者位置

传统的 SSA 在迭代过程中执行全局探索来更新发现者的位置，但位置更新的权重相对较大，并且其位置更新的变化较小，有很大概率会找不到全局的最优解。因此，引入一个非线性递减权重用于周围不存在捕食者时更新发现者的位置，以提高优化迭代过程中发现者的搜索能力，更好找到全局最优解。发现者位置更新变化的计算公式为：

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

$$\omega = \left(\frac{\text{iter}_{\max} - t + 1}{\text{iter}_{\max}}\right)^t \quad (10)$$

式中： $t$ 为当前迭代次数； $X_{i,j}^t$ 为迭代  $t$  时第  $j$  维的第  $i$  个麻雀； $\omega$ 为线性递减权重； $\text{iter}_{\max}$ 为常数，表示最大迭代次数； $\alpha$ 为(0,1)之间的随机数； $Q$ 为一个服从正态分布的随机数； $L$ 为  $1 \times d$  的单位列向量。

4) 加入者的位置更新

传统的 SSA 会根据当前位置与当前全局最差位置的差值更新当前位置。虽然这种方式可以防止饥饿的加入者去不好的地方觅食，但不能保证更新的位置有丰富的食物。本文 ISSA 中，引入一个额外的方程，采用突变策略更新加入者的位置<sup>[24]</sup>，计算公式为：

$$x_{i,j}^{t+1} = x_{i,j}^t + \lambda * (x_{i,j}^{\text{best}} - x_{i,j}^t) \quad (11)$$

式中： $x_{i,j}^{\text{best}}$ 为全局最佳位置； $\lambda$ 为一个随机数，且  $\lambda \in [0,1]$ 。式(11)可以引导饥饿的加入者向全局最佳位置移动。基于当前全局最坏位置的位置更新方程不被替换，而是与式(11)相结合能更好避免陷入局部最优。

另外，当加入者能量储备充足时，它们跟随发现者觅食，一旦观察到发现者找到好的食物，它们就会争夺食物，但 SSA 的局部搜索能力不强，易丢失最优解。混沌扰动具有更好的深度搜索能力，能

避免搜索陷入局部最优。因此，SSA 结合混沌扰动可以提高加入者对最佳觅食区域的探索能力。

$$X_T = \begin{cases} 2x_i & 0 \leq x_i \leq 0.5 \\ 2(1-x_i) & 0.5 < x_i \leq 1 \end{cases} \quad (12)$$

$$X_j^{\text{chaos}} = px_j + X_T * (x_j^{\text{best}} - px_j) \quad (13)$$

$$X_j^{\text{chaos\_New}} = \eta px_j + (1-\eta)X_j^{\text{chaos}} \quad (14)$$

改进后加入者位置更新计算公式为：

$$x_{i,j}^{t+1} = \begin{cases} \min(Q \cdot \exp\left(\frac{x_{i,j}^{\text{worst}} - x_{i,j}^t}{i^2}\right), x_{i,j}^t) + \lambda \cdot (x_{i,j}^{\text{best}} - x_{i,j}^t) & i > \frac{n}{2} \\ \min(x_p^{t+1} + |x_{i,j}^{t+1} - x_p^{t+1}| * A^+ * L, \eta px_j + (1-\eta)X_j^{\text{chaos}}) & \text{其他} \end{cases} \quad (15)$$

利用混沌扰动增强局部搜索的步骤如下：

步骤 1 通过式(12)产生一个混沌变量  $X_T$ ，其中  $X_T$ 为一个均匀分布在区间[0,1]随机数。

步骤 2 根据式(13)， $X_T$ 被用来产生一个混沌扰动变量  $X_j^{\text{chaos}}$ ，其中  $px_j$ 为当前执行的混沌搜索操作的第  $j$  维值； $x_j^{\text{best}}$ 为全局最优位置的第  $j$  维值。

步骤 3 式(14)给出了混沌扰动的运行过程，其中  $x_j^{\text{chaos\_new}}$ 为在一个混沌扰动后的新结果第  $j$  维度值； $\eta$ 为一个均匀分布在区间[0,1]的随机数。

步骤 4 最后，根据式(15)更新加入者位置。

5) 更新侦察者的位置

在仿真中，假设其中 15%左右的麻雀能够意识到危险，将这些麻雀作为侦察者。侦察者的初始位置是随机产生的，其表达式为：

$$X_{i,j}(t+1) = \begin{cases} X_{\text{best}}(t) + \beta \cdot |X_{i,j}(t) - X_{\text{best}}(t)|, f_i > f_g \\ X_{i,j}(t) + K \cdot \left(\frac{|X_{i,j}(t) - X_{\text{worst}}(t)|}{(f_i - f_w) + \varepsilon}\right), f_i = f_g \end{cases} \quad (16)$$

式中： $X_{\text{best}}(t)$ 为当前的最优位置； $\beta$ 为控制步长的参数； $K \in [-1,1]$ 为一个随机数； $f_i$ 为麻雀的适应度值； $f_g$ 和  $f_w$ 分别为当前全局最佳和最差的适应度值； $\varepsilon$ 为一个很小的数值。

2.2 门控循环单元

GRU 是一种循环神经网络 (recurrent neural network, RNN) 的变体，由 Cho 等人于 2014 年提出，它可以处理序列数据，如文本、语音和时间序

列等<sup>[25-26]</sup>,其单元结构如图2所示。GRU可以有选择地存储较为重要的信息,并遗忘不重要的信息,同时它也能很好地解决LSTM神经网络等传统循环神经网络存在的梯度爆炸及长期记忆的问题,其运算效率也较高<sup>[23]</sup>。GRU的运算表达式为:

$$\begin{cases} z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \\ \tilde{h}_t = \tanh(W_h x_t + U_h (r_t \otimes h_{t-1}) + b_h) \\ h_t = (1 - z_t) \otimes h_{t-1} + z_t \otimes \tilde{h}_t \end{cases} \quad (17)$$

式中:  $\otimes$  为矩阵中的各个元素相乘;  $W_z$ 、 $W_r$ 、 $W_h$ 、 $U_z$ 、 $U_r$  和  $U_h$  分别为权重系数;  $b_z$ 、 $b_r$ 、 $b_h$  分别为输入参数的偏置;  $z_t$  和  $r_t$  分别为更新门和重置门  $t$  时刻的输出;  $x_t$  为  $t$  时刻输入;  $h_{t-1}$  为  $t-1$  时刻的输出;  $h_t$  为  $t$  时刻的输出;  $\tilde{h}_t$  为待更新参数;  $\sigma$  为 sigmoid 函数。




图2 GRU 单元结构  
Fig.2 Structure of the GRU unit

由图2可知,  $\tilde{h}_t$  是由  $h_{t-1}$  与  $x_t$  共同决定的,重置门  $r_t$  决定了  $x_t$  与  $h_{t-1}$  相结合的比重,并存储短期记忆中的信息;同时  $h_t$  中包含了  $h_{t-1}$  和  $\tilde{h}_t$ ,并由更新门  $z_t$  来设置权重,  $z_t$  能存储长期记忆中的信息。此时,长期记忆和短期记忆组合起来,一起组成了GRU单元  $t$  时刻的输出  $h_t$ ,然后将其输入下一个GRU单元中。

### 2.3 ISSA 优化 GRU

GRU 中各个参数的设置非常重要,参数设置会影响模型的结构和性能,不同的参数组合可能会导致不同的预测结果。同时,参数设置需要平衡模型的复杂度和泛化能力,过大或过小的参数可能会导致过拟合或欠拟合的问题,影响模型在未知数据上的预测效果。因此本文引入 ISSA 来对 GRU 中的参数进行优化,利用 ISSA 模拟麻雀的觅食和返捕食

行为,来寻找最优的参数组合,以提高 GRU 预测的有效性和准确性,ISSA-GRU 流程如图3所示。

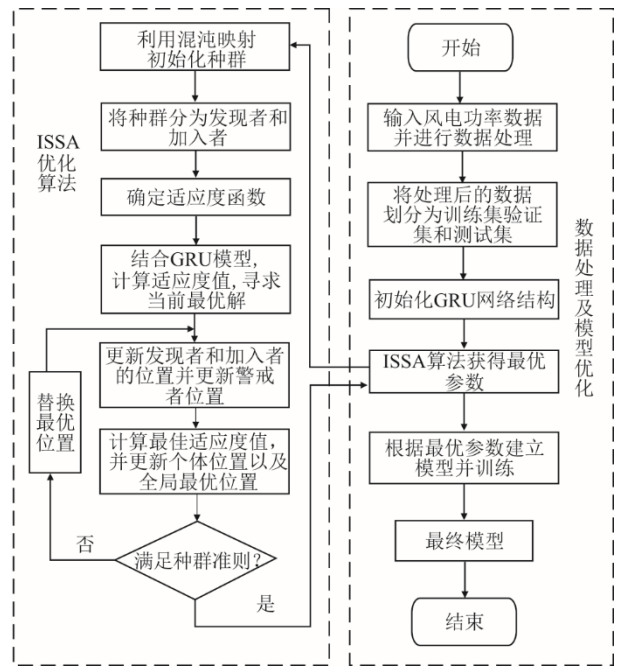


图3 ISSA-GRU 流程  
Fig.3 Flowchart of the ISSA-GRU

### 2.4 VMD-ISSA-GRU 模型

相较于 LSTM 模型,GRU 模型参数量少,训练速度快,但也可能导致表达能力不足,无法捕捉复杂的序列特征,同时 GRU 模型也存在梯度爆炸的风险<sup>[27]</sup>。因此本文在 GRU 模型中引入 VMD,可以有效地降低信号的复杂度和噪声干扰,提高信号的平稳性和可分辨性,同时也可以有效减少 GRU 模型的输入维度和参数数量,提高 GRU 模型的训练速度和准确性。图4为 VMD-ISSA-GRU 流程。

结合 VMD、ISSA 算法以及 GRU 模型,本文搭建 VMD-ISSA-GRU 组合模型,其运行步骤如下:

1) 通过 VMD 将原始风电功率数据  $X(t)$  分解,得到  $n$  个子序列,其表达式为:

$$X(t) = \sum_{i=1}^n \text{IMF}_i(t) + \text{Re}(t) \quad (18)$$

2) 将分解得到的各个分量输入搭建的 ISSA-GRU 模型中,并运用改进麻雀搜索算法对 GRU 中各个参数(隐藏层层数、隐藏层节点数以及丢失率)进行寻优,然后用训练结束后的模型进行功率预测。

3) 各个序列经过训练后的模型会预测出其对应的功率值,将这  $n$  个数值进行相加,便能得到最终的预测结果。

4) 误差分析。

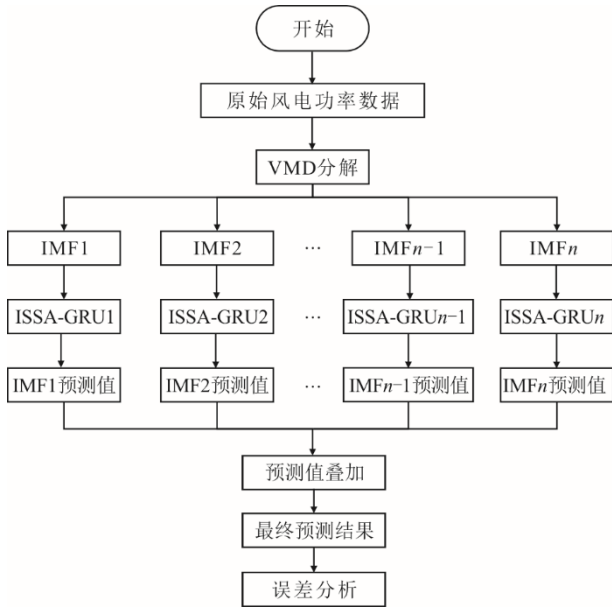


图 4 VMD-ISSA-GRU 流程  
Fig.4 Flowchart of the VMD-ISSA-GRU

### 3 算例分析

本文采用 Kaggle 上德国 TenneT TSO 能源公司的风力发电数据，选取 2020 年 8.1—8.10 的风力发电数据，采样间隔为 15 min，每天采样 96 个点，10 天总计 960 个采样点，本文采用均值插补法对其中的缺失值、异常值进行处理，以便更好地用于模型的训练以及预测，提高预测精度，其风电功率曲线如图 5 所示。




图 5 原始风电功率曲线  
Fig.5 The original wind power curve

#### 3.1 数据划分及评价指标

为了更好地适应于模型的训练，将原始数据按照 8:1:1 划分为训练集、验证集以及测试集。本文采用的评价指标有平均绝对误差 (mean absolute

error,  $\delta_{MAE}$ )、平均绝对百分比误差 (mean absolute percentage error,  $\delta_{MAPE}$ )、均方根误差 (root mean square error,  $\delta_{RMSE}$ )，其表达式为：

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (19)$$

$$\delta_{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (20)$$

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

式中： $y_i$  为真实值； $\hat{y}_i$  为预测值。

#### 3.2 VMD 分解个数 $K$ 的选择

VMD 能将风电功率分解为多个窄带信号，每个信号有单一频率和模式，这样能降低数据的复杂度和不稳定性，突出信号的时频特征。但是， $K$  值的选择至关重要， $K$  值过小，会导致信号的重要信息被过滤或混合； $K$  值过大，会导致信号的过分解或模式重复<sup>[28]</sup>。因此本文通过对中心频率的观察来确定  $K$  值，当分解得到的最后一层分量的中心频率达到稳定时，可获得最佳  $K$  值。其他参数：惩罚系数  $\alpha$  取 1 000，收敛容差  $tol$  取  $5 \times 10^{-6}$ ，拉格朗日乘子更新率  $\tau$  取 0.01。在 MATLAB 上进行实验，实验结果如图 6 及表 1 所示。由表 1 可见，在分解次数为 7 和 8 时，它们最后一个模态中心频率相差不大，趋于稳定，且倒数第 2 个模态的中心频率也近似，因此，当  $K=7$  时，VMD 分解效果达到最佳。




图 6 VMD 分解原始数据  
Fig.6 Decomposition of raw data using VMD

表 1 不同  $K$  值下中心频率  
Tab.1 Center frequency of different  $K$  values

$K$	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
2	0.000 3	0.015 0						
3	0.000 2	0.011 1	0.034 8					
4	0.000 1	0.009 4	0.021 6	0.047 6				
5	0.000 1	0.009 2	0.020 5	0.042 0	0.163 3			
6	0.000 1	0.008 9	0.019 3	0.033 9	0.060 7	0.233 1		
7	0.000 1	0.008 8	0.019 1	0.033 3	0.056 1	0.160 9	0.302 0	
8	0.000 1	0.008 7	0.018 8	0.032 1	0.049 9	0.091 7	0.169 0	0.307 6

### 3.3 确定输入的时间步长

使用不同的时间步长可能会出现不同的结果，因此本小节使用 GRU 作为基础模型来确定输入的时间步长，步长范围设定为[1,10]，对于不同的时间步长分别进行仿真，其结果如图 7 所示。从图 7 可以看出，当步长设置为 4 时，所对应的平均绝对误差、均方根误差为最小，此时预测精度最高，因此后续的实验仿真输入时间步长统一设置为 4。单时间序列输入步长与输出结果如图 8 所示。




图 7 GRU 模型预测误差随时间步长的变化  
Fig.7 Change of prediction errors of the GRU model with time step

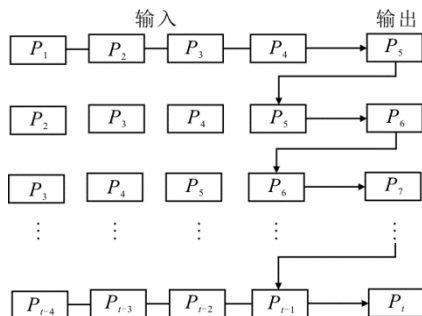


图 8 单时间序列输入步长与输出结果  
Fig.8 The single time series input step size and the output result

图 8 中  $P$  为风电功率， $P_t$  表示  $t$  时刻的风电功率，若要预测  $t$  时刻的风电功率，则要输入  $t-4$ 、 $t-3$ 、

$t-2$ 、 $t-1$  时刻的风电功率数据，即进行单点预测，输入历史前 4 个点的数据，得到第 5 个点的预测值。

### 3.4 VMD 有效性验证

为验证 VMD 的有效性，首先将原始数据通过 VMD 进行分解，再将分解后的各个子序列分别输入 GRU、LSTM、BiLSTM 模型中，得到各个误差，并与不采用 VMD 直接利用这 2 个模型进行预测的预测误差进行对比，结果见表 2。

表 2 VMD 分解前后误差比较  
Tab.2 Error comparison before and after VMD decomposition

模型	$\delta_{MAE}/MW$	$\delta_{MAPE}/\%$	$\delta_{RMSE}/MW$
GRU	3.031 3	4.660 1	3.743 8
VMD-GRU	2.976 9	4.362 0	3.590 9
LSTM	3.335 8	5.191 4	4.060 1
VMD-LSTM	3.151 8	4.619 5	3.812 0
BiLSTM	3.052 5	4.672 2	3.800 5
VMD-BiLSTM	2.580 0	3.765 6	3.096 0

由表 2 可知，在使用 VMD 对原始风电功率序列进行分解后，模型的预测精度都有一定的提高，其中，VMD-GRU 模型相较于 GRU 模型，平均绝对误差、平均绝对百分比误差、均方根误差分别降低了 1.79%、6.40%、4.08%，VMD-LSTM 模型相较于 LSTM 模型，平均绝对误差、平均绝对百分比误差、均方根误差分别降低了 1.65%、11.02%、6.11%。VMD-BiLSTM 模型相较于 BiLSTM 模型，平均绝对误差、平均绝对百分比误差、均方根误差分别降低了 15.48%、19.40%、18.54%。实验结果表明 VMD 能降低原始数据的噪声以及复杂程度，将分解后的数据输入模型中能提高模型的预测精度。

### 3.5 模型参数设置

采用一些神经网络以及优化算法进行对比，为了更方便实验的对比，将模型和算法的各个参数统

一设置,其中神经元个数设置为 16, epochs 为 200, 初始学习率为 0.001, Batchsize 为 75, 优化算法种群个数为 4, 进化次数为 15。同时设置优化算法优化的超参数范围,其中隐藏层层数优化范围为[1,3], 神经元个数范围为[2,50], 丢失率范围为(0,0.005)。

### 3.6 实验结果分析

为了更好地验证本文提出组合模型的预测能力,针对不同模型以及算法建立了不同的组合模型,分别进行实验,参数按照上节所示设置,时间步长统一设置成 4,可以得到如图 9 所示的各个基础模型对应最优组合模型的结果比较,各组合模型误差指标见表 3。

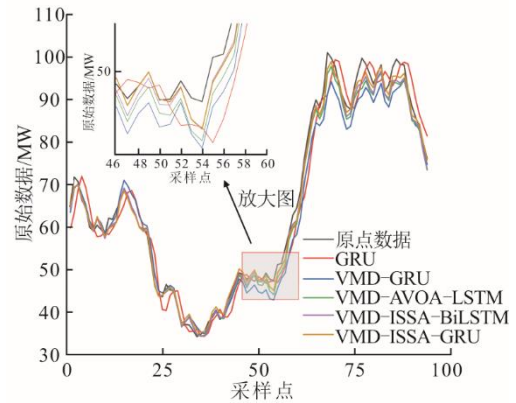


图 9 各个最优模型与 GRU 模型预测结果  
Fig.9 Prediction results of various optimal models and GRU model

表 3 各组合模型误差指标

Tab.3 Error indicators for each combined model

模型	GRU			LSTM			BiLSTM		
	$\delta_{MAE}$	$\delta_{MAPE}/\%$	$\delta_{RMSE}$	$\delta_{MAE}$	$\delta_{MAPE}/\%$	$\delta_{RMSE}$	$\delta_{MAE}$	$\delta_{MAPE}/\%$	$\delta_{RMSE}$
单一	3.031 3	4.660 1	3.743 8	3.335 8	5.191 4	4.060 1	3.052 5	4.672 2	3.800 5
VMD	2.976 9	4.362 0	3.590 9	3.151 8	4.619 5	3.812 0	2.580 0	3.765 6	3.096 0
VMD-GWO	1.473 9	2.140 0	1.907 8	2.697 8	3.860 0	3.362 0	1.978 2	2.880 0	2.471 2
VMD-PSO	1.353 9	2.020 0	1.766 8	1.801 9	2.570 0	2.298 2	1.556 9	2.280 0	1.998 7
VMD-AVOA	1.563 9	2.430 0	1.957 5	1.768 6	2.550 0	2.263 5	1.584 5	2.440 0	2.008 5
VMD-ISSA	1.211 8	1.890 0	1.591 6	1.985 3	2.780 0	2.526 8	1.355 8	1.950 0	1.797 6

由表 3 的数据可知,相较于单一模型或者未使用优化算法进行参数寻优的模型,使用 VMD 技术且加入优化算法进行参数寻优的组合模型预测精度更高,预测结果与原始数据的拟合程度更好。结合表 3 中的数据可知, VMD-ISSA-GRU 组合模型相较于 GRU 以及 VMD-GRU 模型,其平均绝对误差分别降低了 60.02%与 59.69%;平均绝对百分比误差分别降低了 59.44%与 56.67%;均方根误差分别降低了 57.49%与 55.68%;使用其他优化算法同样也对模型的精度有一定的提升,如 VMD-PSO-GRU 模型相较于 GRU 以及 VMD-GRU 模型,其平均绝对误差分别降低了 55.34%与 54.52%;其平均绝对百分比误差分别降低了 56.65%与 53.69%;其均方根误差分别降低了 52.81%与 50.80%。同样的,以 LSTM、BiLSTM 为基础模型的其他组合模型相较于单一模型在预测误差上也都有不同程度的降低,可见在加入变分模态分解对原始数据进行处理以及使用优化算法对基础模型的超参数进行寻优后,能更好提高模型的性能,并提高预测精度。将 GRU、LSTM、BiLSTM 中最优的组合模型进行比较,本文使用混沌映射、非线性递减权重以及一个突变策略来改进的麻雀搜索算法相较于其他优化算法具有更高的预测精度,其中 VMD-ISSA-GRU

组合模型相较于 VMD-AVOA-LSTM 以及 VMD-ISSA-BiLSTM 组合模型,其平均绝对误差分别降低了 31.48%与 10.62%;其平均绝对百分比误差分别降低了 25.88%与 3.08%;其均方根误差分别降低了 29.68%与 11.50%。

### 3.7 模型普适性验证

为了验证本文提出模型的普适性,选取 Kaggle 上另外一家德国能源公司 Amprion 风力发电数据进行模型性能的验证,后面将这个数据集分别简称为 AM 数据集,同样每 15 min 采样一次,10 天共计 960 个采样点,将数据集按照 8:1:1 进行划分为训练集、验证集以及测试集,对模型进行训练并验证其性能,模型参数等保持不变,训练结果如图 10 以及表 4 所示。由表 4 可知,本文提出的 VMD-ISSA-GRU 模型相较于 GRU、VMD-GRU 以及 ISSA-GRU 模型,其平均绝对误差分别降低了 68.16%、57.48%以及 57.35%;其平均绝对百分比误差分别降低了 65.43%、49.89%以及 55.96%;其均方根误差分别降低了 68.88%、60.43%以及 61.02%。可见, VMD-ISSA-GRU 模型相较于传统 GRU 模型或仅使用 VMD 或者 ISSA 中一种方法的模型具有更高的精度。同样的,相较于 VMD-ISSA-BiLSTM 组合模型,其平均绝对误差、平均绝对百分比误差、均方

根误差分别降低了 14.52%、15.27%以及 11.78%。因此,本文提出的 VMD-ISSA-GRU 组合模型具有一定的普适性,且相较于其他模型具有更高的预测精度。




图 10 AM 数据集上各模型的预测结果

Fig.10 Prediction results of each model on the AM dataset

表 4 各模型在 AM 数据集上的误差

Tab.4 Errors of each model on the AM dataset

模型	$\delta_{MAE}/MW$	$\delta_{MAPE}/\%$	$\delta_{RMSE}/MW$
GRU	2.403 3	5.828 0	3.040 7
VMD-GRU	1.799 3	4.020 7	2.391 3
ISSA-GRU	1.793 8	4.575 0	2.427 9
VMD-AVOA-LSTM	1.280 1	3.237 5	1.520 5
VMD-ISSA-BiLSTM	0.895 1	2.378 0	1.072 7
VMD-ISSA-GRU	0.765 1	2.014 8	0.946 3

## 4 结 语

本文针对风电功率波动和不平稳的特性以及提高风电功率预测精度的问题上,提出了一种通过中心频率法确定 VMD 分解次数,并且通过 VMD 将复杂的风电功率数据分解成多个子序列,分别结合 ISSA 优化的 GRU 对各个子序列进行训练预测,最后将预测结果叠加得到最终预测结果,主要结论如下。

1) 本文通过中心频率法确定 VMD 分解次数能够更好地分解风电功率数据,有效避免了分解不充分以及过分解的问题,更加有利于后续模型的训练与预测,能够有效提高模型预测精度。

2) 通过引入混沌映射来初始化麻雀搜索算法的种群位置,使用非线性递减权重以及突变策略来更新发现者和加入者的位置,能更好地解决传统 SSA 种群初始化混乱、加入者发现者位置更新不到位的问题,并利用 ISSA 对 GRU 进行参数寻优,以便更好地设置模型的超参数。

3) 本文提出的 VMD-ISSA-GRU 组合模型通过使用 VMD 以及 ISSA 解决了风电功率数据复杂、波动大以及 GRU 参数设置困难的问题,在 AM 数据集上,其平均绝对误差、平均绝对百分比误差、均方根误差相较于 GRU 分别降低了 68.16%、65.43%、68.88%,且相较于其他组合模型,误差更小,具有更高的预测精度。

虽然本文模型在超短期风电功率预测精度上相较于其他模型有一定的提升,但是风电功率受风速、温度、气压等因素的影响,本文在预测过程中未考虑,因此后续会将这些因素作为特征输入模型中,以便进一步提高预测精度。

## [参 考 文 献]

- [1] CAO B, CHANG L C. Development of short-term wind power forecasting methods[M]. 2022 IEEE 7th Southern Power Electronics Conference (SPEC). IEEE, 2022: 1-5.
- [2] SUN Y, LI Z Y, YU X N, et al. Research on ultra-short-term wind power prediction considering source relevance[J]. IEEE Access, 2020, 8: 147703-147710.
- [3] YAN J, ZHANG H, LIU Y Q, et al. Forecasting the high-penetration of wind power on multiple scales using multi-to-multi mapping[J]. IEEE Transactions on Power Systems, 2018, 33(3): 3276-3284.
- [4] 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.
- [5] 钱政, 裴岩, 曹利霄, 等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060. QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [6] 韩自奋, 景乾明, 张彦凯, 等. 风电预测方法与新趋势综述[J]. 电力系统保护与控制, 2019, 47(24): 178-187. HAN Zifen, JING Qianming, ZHANG Yankai, et al. Review of wind power forecasting methods and new trends[J]. Power System Protection and Control, 2019, 47(24): 178-187.
- [7] 张怡, 杨宇晴. 基于 AM-LSTM 的风电场内多点位风电功率预测[J]. 计算机仿真, 2021, 38(10): 145-148. ZHANG Yi, YANG Yuqing. Multi-point wind power prediction in wind farms based on AM-LSTM[J]. Computer Simulation, 2021, 38(10): 145-148.
- [8] 李森文, 张伟, 李纯宇, 等. 基于 SSA-LSTM 的海上风电功率预测[J]. 机械与电子, 2022, 40(6): 22-25. LI Senwen, ZHANG Wei, LI Chunyu, et al. Power prediction of offshore wind farm based on SSA-LSTM[J]. Machinery & Electronics, 2022, 40(6): 22-25.
- [9] 王愈轩, 梁沁雯, 章思远, 等. 基于 LSTM-XGboost 组合的超短期风电功率预测方法[J]. 科学技术与工程, 2022, 22(14): 5629-5635. WANG Yuxuan, LIANG Qinwen, ZHANG Siyuan, et al.

- An ultra-short-term wind power prediction method based on LSTM-XGboost combination[J]. *Science Technology and Engineering*, 2022, 22(14): 5629-5635.
- [10] 王斌, 魏成伟, 谢丽蓉, 等. 基于风速误差校正和ALO-LSSVM的风电功率预测[J]. *太阳能学报*, 2022, 43(1): 58-63.  
WANG Bin, WEI Chengwei, XIE Lirong, et al. Wind power forecasting based on wind speed error correction and ALO-LSSVM[J]. *Acta Energetica Solaris Sinica*, 2022, 43(1): 58-63.
- [11] 张涛, 朱瑞金, 扎西顿珠. 基于改进骨干差分进化算法优化LSSVM的短期光伏发电功率预测[J]. *热力发电*, 2021, 50(5): 102-107.  
ZHANG Tao, ZHU Ruijin, ZHAXI Dunzhu, et al. Short-term photovoltaic power prediction based on IBBDE-LSSVM[J]. *Thermal Power Generation*, 2021, 50(5): 102-107.
- [12] 李宏扬, 高丙朋. 基于改进VMD和SNS-Attention-GRU的短期光伏发电功率预测[J]. *太阳能学报*, 2023, 44(8): 292-300.  
LI Hongyang, GAO Bingpeng. Short-term PV power forecasting based on improved VMD and SNS-Attention-GRU[J]. *Acta Energetica Solaris Sinica*, 2023, 44(8): 292-300.
- [13] DAN F C, HORA C, BENDEA G. Short-term forecasting of wind power generation[C]. 2021 10th International Conference on Energy and Environment (CIEM). 2021: 1-5.
- [14] 张振中, 郭傅傲, 刘大明, 等. 基于最大互信息系数和小波分解的多模型集成短期负荷预测[J]. *计算机应用与软件*, 2021, 38(5): 82-87.  
ZHANG Zhenzhong, GUO Fuao, LIU Daming, et al. Multi-model integrated short-term load prediction based on maximum mutual information coefficient and wavelet decomposition[J]. *Computer Applications and Software*, 2021, 38(5): 82-87.
- [15] 余周, 姜涛, 范鹏辉, 等. 基于EMD-DELM-LSTM组合模型的湖泊水位多时间尺度预测[J/OL]. *长江科学院院报*: 1-9 [2024-03-01]. <http://kns.cnki.net/kcms/detail/42.1171.TV.20230413.1830.002.html>.  
YU Zhou, JIANG Tao, FAN Penghui, et al. Multi-time scale prediction for lake level based on EMD-DELM-LSTM combined model[J/OL]. *Journal of Changjiang River Scientific Research Institute*: 1-9 [2024-03-01]. <http://kns.cnki.net/kcms/detail/42.1171.TV.20230413.1830.002.html>.
- [16] 侯金霄, 黄林显, 胡晓农, 等. 基于EMD-LSTM耦合模型的趵突泉岩溶地下水水位预测应用[J]. *水资源与水工程学报*, 2023, 34(4): 92-98.  
HOU Jinxiao, HUANG Linxian, HU Xiaonong, et al. Application of EMD-LSTM coupled model to karst groundwater level prediction in Baotu Spring[J]. *Journal of Water Resources and Water Engineering*, 2023, 34(4): 92-98.
- [17] 张云钦, 程起泽, 蒋文杰, 等. 基于EMD-PCA-LSTM的光伏功率预测模型[J]. *太阳能学报*, 2021, 42(9): 62-69.  
ZHANG Yunqin, CHENG Qize, JIANG Wenjie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM[J]. *Acta Energetica Solaris Sinica*, 2021, 42(9): 62-69.
- [18] TATINATI S, WANG Y, KHONG A W H. Hybrid method based on random convolution nodes for short-term wind speed forecasting[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 7019-7029.
- [19] WANG Z, WANG L, REVANESH M, et al. Short-term wind speed and power forecasting for smart city power grid with a hybrid machine learning framework[J]. *IEEE Internet of Things Journal*, 2023, 10(21): 18754-18765.
- [20] 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.
- [21] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [22] 薛建凯. 一种新型的群智能优化技术的研究与应用[J]. 上海: 东华大学, 2020: 1-10.  
XUE Jiankai. Research and application of a novel swarm intelligence optimization technique: sparrow search algorithm[J]. Shanghai: Dong Hua University, 2020: 1-10.
- [23] SONG W, LIU S, WANG X C, et al. An improved sparrow search algorithm[C]. 2020 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Social Computing & Networking (ISPA/BDC/Social Com/SustainCom). 2020: 537-543.
- [24] MA B, LU P M, ZHANG L F, et al. Enhanced sparrow search algorithm with mutation strategy for global optimization[J]. *IEEE Access*, 2021, 9: 159218-159261.
- [25] GU Y, WANG F D, LI M K, et al. A digital load forecasting method based on digital twin and improved GRU[C]. 2022 Asian Conference on Frontiers of Power and Energy (ACFPE). 2022: 462-476.
- [26] CHO K, VAN M B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2014: 1724-1734.
- [27] GAO L, ZHAO L J, KONG F, et al. Research method of ultra-short-term wind power prediction based on PSO-GRU prediction[C]. 2022 8th Annual International Conference on Network and Information Systems for Computers (ICNISC). 2022: 967-972.
- [28] ZHANG H R, ZHANG Y Y, XU Z W. Thermal load forecasting of an ultra-short-term integrated energy system based on VMD-CNN-LSTM[M]. 2022 International Conference on Big Data, Information and Computer Network (BDICN). 2022: 264-279.

(责任编辑 杜亚勤)