

# 基于 ICEEMDAN-SE-MSGJO-LSTM-EC 的短期风电功率预测

刘志坚\*, 孙瑞星, 黄建, 张江云, 何超  
(昆明理工大学 电力工程学院, 云南 昆明 650500)

## Short-Term Wind Power Prediction Based on ICEEMDAN-SE-MSGJO-LSTM-EC

LIU Zhijian\*, SUN Ruixing, HUANG Jian, ZHANG Jiangyun, HE Chao

(Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650000, China)

**Abstract:** In order to improve the accuracy of short-term wind power prediction, this paper proposes a short-term wind power prediction model based on the ICEEMDAN-SE-MSGJO-LSTM-EC model. Firstly, the original wind power signal is decomposed using intrinsic computing expressive empirical mode decomposition with adaptive noise (ICEEMDAN) and reconstructed by adding components with similar entropy values through sample entropy calculation; Secondly, establish an multi-strategy golden jackal optimization (MSGJO)-long short-term memory network (LSTM) prediction model, optimize the LSTM network parameters through the improved MSGJO, and predict various modal components; Finally, error correction (EC) is applied to the prediction results of each modal component and all modal prediction results are added to obtain the final prediction result. Taking a wind farm in Xinjiang as an example, simulation analysis was conducted using the prediction model proposed in this paper. The experimental results showed that the prediction model based on ICEEMDAN-SE-MSGJO-LSTM-EC proposed in this paper has higher prediction accuracy.

**Key words:** wind power prediction; error correction; intrinsic computing expressive empirical mode decomposition with adaptive noise (ICEEMDAN); multi-strategy golden jackal optimization (MSGJO); long short-term memory network (LSTM)

**摘要:** 为了提高风电功率短期预测精度,本文提出了一种基于 ICEEMDAN-SE-MSGJO-LSTM-EC 模型的短期风电

功率预测模型。首先,通过 ICEEMDAN 对原始风功率信号进行分解并通过样本熵计算熵值相近的分量相加重构。其次,建立 MSGJO-LSTM 预测模型,通过改进金豺优化算法(MSGJO)优化 LSTM 网络参数,对各模态分量进行预测。最后,通过对各模态分量预测结果进行误差修正(EC)并将所有模态预测结果相加得到最终预测结果。以新疆某风电场为例,采用本文所提预测模型进行仿真分析,试验结果表明本文基于 ICEEMDAN-SE-MSGJO-LSTM-EC 的预测模型预测精度更高。

**关键词:** 风电功率预测; 误差修正; 改进自适应噪声完全集合经验模态分解; 改进金豺优化算法; 长短期记忆网络

## 0 引言

随着“30·60”双碳目标的提出,加快新能源的开发利用能极大地减少对环境的负担<sup>[1]</sup>。风能作为一种绿色可再生能源,得到了广泛应用和发展<sup>[2]</sup>。由于风能具有随机性、波动性和间歇性,当风电接入电网时,对电网的稳定运行造成了巨大冲击,精准的风电预测可以缓解电力系统调度的调峰调频压力,因此对风电功率进行准确预测具有重要意义<sup>[3]</sup>。

研究风电功率预测的方法一般分为两类:物理法<sup>[4-5]</sup>和统计方法<sup>[6-7]</sup>。物理方法是集合风电场地理信息、风机性能参数以及 NWP 信息建模,该方法计算量大、收敛速度慢以及建模过程复杂。统计方法是通过风电功率历史信息和风速、温度等信息建立非线性关系。与物理法建模相比,统计法建模过程简单<sup>[8-9]</sup>,预测精度和泛化性都要优于物理模型,因此统计法受到了广泛应用。常用的统计方法包括人工神经网络<sup>[10]</sup>(ANN)、支持向

基金项目: 云南省基础研究重点项目(202301AS070055)  
Key Basic Research Projects in Yunnan Province  
(202301AS070055)

量机<sup>[11-12]</sup>(SVM)、时间序列法<sup>[8-13]</sup>、自回归移动平均模型<sup>[14-15]</sup>(ARMA)和整合移动平均自回归模型<sup>[16-17]</sup>(ARIMA)。

在预测算法方面,文献[18]将沃尔泰拉(Volterra)泛函模型和前馈(BP)神经网络结合起来,设计了一种混沌时间序列遗传算法-Volterra·神经网络(GA-VNN)模型的学习算法对风电功率进行预测,但BP神经网络可能会陷入局部最优。文献[19]使用卷积神经网络提取数据中的特征信息,并输入到双向门控循环单元(BiGRU)中训练模型,结果表明该方法可有效解决预测滞后现象,但模型自身的预测精度问题没有得到改善。LSTM神经网络作为循环神经网络(RNN)的一种变体,对于长时间序列能够很好的解决RNN梯度消失和梯度爆炸的问题<sup>[20]</sup>,但LSTM神经网络的隐含层神经元个数、学习率和最大迭代次数需要依靠人为经验调参<sup>[21]</sup>;在数据预处理方面,文献[22]首先通过主成分分析法(PCA)对原始多维气象数据变量进行预处理,在利用CNN-LSTM模型进行风功率预测,由于风功率历史数据和NWP数据之间的相关性是非线性的,PCA变换对于非线性相关性的数据不能得到较好的结果。文献[23]通过经验模态分解(EMD)对风功率历史数据进行分解,然后输入到径向基(RBF)神经网络进行风功率预测,但EMD可能会出现模态混叠现象影响最终预测精度。文献[24]通过变分模态分解(VMD)对风功率历史数据进行分解,然后输入到LSSVM网络进行风功率预测,但VMD模态分解数量和拉格朗日乘子需人为经验确定,直接影响分解最终效果。

本文提出一种基于ICEEMDAN-SE-MSGJO-LSTM-EC的短期风电功率预测模型。首先,针对风电功率具有较强的波动性和随机性,利用ICEEMDAN分解原始风电功率时间序列;其次,对不同序列建立LSTM模型,并引入MSGJO对LSTM参数进行寻优;最后对预测结果进行误差修正并对所有序列预测结果相加得到最终预测结果。本文对LSTM、ICEEMDAN-LSTM、ICEEMDAN-SE-LSTM、ICEEMDAN-SE-PSO/GJO/MSGJO-LSTM和ICEEMDAN-SE-MSGJO-LSTM-EC模型进行对比,通过实例分析验证了本文所提模型ICEEMDAN-SE-MSGJO-LSTM-EC的有效性和优越性。

## 1 数据预处理

### 1.1 ICEEMDAN

ICEEMDAN分解算法是在EMD的基础上对信号添加均值为1和方差为0的白噪声进行处理,将原始信号分解为k个IMF分量和一个残差分量。ICEEMDAN分解流程如下:

1) 引入EMD中的局部均值算子 $M(\cdot)$ 和k阶模式下原始信号 $f(t)$ 分解算子 $E_k(t)$ ;

2) 添加白噪声的分解序列 $x^i(t)=x(t)+\varepsilon_0 E_1[\xi^i(t)]$ ,计算得到第一个残基:

$$r_1 = \{M[x^i(t)]\} \quad (1)$$

式中: $\varepsilon_0=\delta_0 \text{std}(x)/\text{std}\{E_1[\xi^i(t)]\}$ ; $\delta_0$ 为首次加噪信号和分析信号间的期望信噪比倒数; $\text{std}$ 为标准差; $\langle \cdot \rangle$ 为对整体求平均;

3) 计算得出 $k=1$ 时的第一模态:

$$IMF_1(t) = x(t) - r_1(t) \quad (2)$$

4) 通过 $r_1(t)+\varepsilon_1 E_2[\xi^i(t)]$ 局部均值的平均值计算得到第二个模态分量:

$$IMF_2(t) =$$

$$r_1(t) - \langle M\{r_1(t) + \omega_1 E_2[\xi^i(t)]\} \rangle \quad (3)$$

5) 推导出第k个残差和模态分量:

$$r_k(t) = \langle M\{r_{k-1}(t) + \omega_{k-1} E_k[\xi^i(t)]\} \rangle \quad (4)$$

$$IMF_k(t) = r_{k-1}(t) - r_k(t) \quad (5)$$

重复步骤5),计算得到信号分解之后所有的IMF分量和残差分量。

### 1.2 样本熵

样本熵不依赖于数据的长度,相比于一般方法其鲁棒性和一致性更好,序列复杂性越高则熵值越大。样本熵计算过程如下:

1) 将原始序列 $f(t)$ 重构为m维向量:

$$\mathbf{Y}(t) = [y(t), y(t+1), \dots, y(t+m-1)] \quad (6)$$

2) 定义向量 $\mathbf{Y}(t)$ 和向量 $\mathbf{Y}(k)$ 之间的距离为两向量对应元素相差最大值:

$$\mathbf{D}_m[\mathbf{Y}(t), \mathbf{Y}(k)] = \max_{0 \leq z \leq m-1} \{|y(t+z) - y(k+z)|\} \quad (7)$$

3) 设定一个小于0的阈值 $r$ ,计算 $\mathbf{D}_m[\mathbf{Y}(t), \mathbf{Y}(k)] < r$ 的个数和 $r$ 与距离总数 $N-m$ 的比值 $B_t^m(r)$ ,对 $B_t^m(r)$ 求平均得到 $B^m(r)$ :

$$B^m(r) = \frac{1}{N-m+1} \sum_{t=1}^{N-m+1} B_t^m(r) \quad (8)$$

4) 对  $m+1$  重复上述步骤, 得到  $B^{m+1}(r)$ ;

5) 对有限值  $N$ , 样本熵表达式为

$$S_{SE}(m, r, N) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (9)$$

式中:  $m$  为嵌入维数, 一般取 1 或 2;  $r$  为相似容限, 一般取  $0.1 * std - 0.25 * std$ 。

## 2 基于 ICEEMDAN-SE-MSGJO-LSTM-EC 的组合预测模型

### 2.1 LSTM 网络

长短期记忆网络 (LSTM) 是循环神经网络 (RNN) 的一种特殊变体。既具有 RNN 的递归属性, 又具有记忆和遗忘模式。可以很好地解决 RNN 梯度消失和梯度爆炸的问题, 能够充分挖掘历史信息<sup>[25]</sup>。LSTM 网络结构图如图 1 所示。

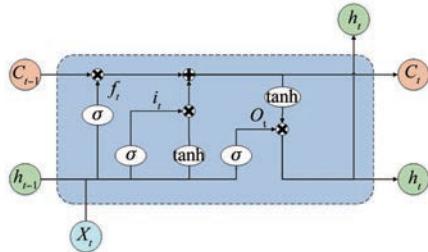


图 1 LSTM 网络结构图

Fig. 1 LSTM network structure diagram

如图 1 所示为 LSTM 网络结构图。LSTM 单元中有三个门, 即输入门、遗忘门和输出门。 $t$  时刻 LSTM 单元输入信息为  $t$  时刻输入数据  $x_t$ 、 $t-1$  时刻细胞状态  $C_{t-1}$  和  $t-1$  时刻隐藏层输出  $h_{t-1}$ ; 输出信息为  $t$  时刻隐藏层输出  $h_t$  和  $t-1$  时刻细胞状态  $C_t$ 。各控制门的更新过程如下:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (10)$$

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

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (12)$$

式中:  $i_t$ 、 $f_t$ 、 $o_t$  分别为输入门、遗忘门和输出门  $t$  时刻的输出;  $W_{xi}$ 、 $W_{xf}$ 、 $W_{xo}$  和  $b_i$ 、 $b_f$ 、 $b_o$  分别为当前  $t$  时刻输入门、遗忘门、输出门的权重矩阵和偏置矩阵;  $W_{hi}$ 、 $W_{hf}$ 、 $W_{ho}$  分别为  $t-1$  时刻输入门、遗忘门和输出门隐藏层输出  $h_{t-1}$  的权重系数;  $\sigma$  为 sigmoid 激活函数, 控制其输出在  $[0, 1]$  之间。

### 2.2 GJO 优化算法

金豺优化算法 (GJO) 是由 Nitish Chopra 等人于 2022 年提出的一种元启发式算法<sup>[26]</sup>。GJO 算

法的灵感来源于金豺的协作狩猎行为。算法包括三个步骤: 搜索猎物、包围猎物和攻击猎物。在 GJO 算法中, 一对金豺(一只公豺和一只母豺)总是成对狩猎和放松。

1) 猎物初始化表达式为

$$\mathbf{P}_{\text{rey}} = \begin{bmatrix} \mathbf{Y}_{1,1} & \mathbf{Y}_{1,2} & \cdots & \mathbf{Y}_{1,d} \\ \mathbf{Y}_{2,1} & \mathbf{Y}_{2,2} & \cdots & \mathbf{Y}_{2,d} \\ \vdots & \vdots & & \vdots \\ \mathbf{Y}_{n,1} & \mathbf{Y}_{n,2} & \cdots & \mathbf{Y}_{n,d} \end{bmatrix} \quad (13)$$

式中:  $\mathbf{P}_{\text{rey}}$  为猎物矩阵;  $\mathbf{Y}_{i,j}$  为第  $i$  个猎物的第  $j$  维位置;  $n$  为猎物数量;  $d$  为求解问题的维度。

2) 搜索猎物表达式为

$$\mathbf{Y}_1(t) = \mathbf{Y}_M(t) - \mathbf{E} \cdot | \mathbf{Y}_M(t) - rl \cdot \mathbf{P}_{\text{rey}}(t) | \quad (14)$$

$$\mathbf{Y}_2(t) = \mathbf{Y}_{FM}(t) - \mathbf{E} \cdot | \mathbf{Y}_{FM}(t) - rl \cdot \mathbf{P}_{\text{rey}}(t) | \quad (15)$$

式中:  $t$  为当前迭代次数;  $\mathbf{P}_{\text{rey}}(t)$  为猎物的位置向量;  $rl$  为基于莱维分布的随机数;  $\mathbf{Y}_M(t)$  和  $\mathbf{Y}_{FM}(t)$  分别为雄豺和雌豺的位置;  $\mathbf{Y}_1(t)$  和  $\mathbf{Y}_2(t)$  分别为对应于猎物的雄豺和雌豺的更新位置。

3) 包围猎物表达式为

雄性和雌性豺狼一起捕猎的行为的数学模型如下:

$$\mathbf{Y}_1(t) = \mathbf{Y}_M(t) - \mathbf{E} \cdot | rl \cdot \mathbf{Y}_M(t) - \mathbf{P}_{\text{rey}}(t) | \quad (16)$$

$$\mathbf{Y}_2(t) = \mathbf{Y}_{FM}(t) - \mathbf{E} \cdot | rl \cdot \mathbf{Y}_{FM}(t) - \mathbf{P}_{\text{rey}}(t) | \quad (17)$$

### 2.3 GJO 改进策略

1) 双重反向学习策略

双重反向学习策略通过随机产生  $[0, 1]$  的随机数与切换概率  $P$  比较大小, 进而为算法选择不同的反向学习策略。在文中, 若随机数大于  $P$ , 选择 Tent 反向学习, 反之选择透镜反向学习。

Tent 反向学习数学模型描述如下:

$$x_i^{\text{Tent}} = lb + ub - \lambda_i \cdot x'_i \quad (18)$$

$$\lambda_{i+1} = \begin{cases} 2\lambda_i, & 0 \leq \lambda_i \leq 0.5 \\ 2(1 - \lambda_i), & 0.5 < \lambda_i \leq 1 \end{cases} \quad (19)$$

式中:  $x_i^{\text{Tent}}$  为种群中第  $i$  个个体对应的 Tent 反向学习机制生成的解;  $ub$  和  $lb$  分别为搜索空间的上下边界;  $\lambda_i$  为对应的 Tent 混沌映射值。

透镜反向学习数学模型描述如下:

$$X_i = \frac{lb + ub}{2} + \frac{lb + ub}{2k} - \frac{X_i}{k} \quad (20)$$

$$k = \left[ 1 + \left( \frac{t}{t_{\max}} \right)^{1/3} \right]^6 \quad (21)$$

式中: $k$  为透镜成像缩放因子。

## 2) 自适应螺旋搜索策略

将金枪鱼群算法中螺旋觅食策略引入到 GJO 中以避免 GJO 算法陷入局部最优<sup>[27]</sup>。螺旋觅食策略如下:

$$\begin{cases} X_i^{t+1} = \\ \alpha_1(X_{\text{br}}^t + \beta |X_{\text{br}}^t - X_i^t|) + \alpha_2 X_i^t, i = 1 \\ \alpha_1(X_{\text{br}}^t + \beta |X_{\text{br}}^t - X_i^t|) + \alpha_2 X_{i-1}^t, i = 2, 3, \dots, n \end{cases} \quad (22)$$

式中:  $X_{\text{br}}^t$  为搜索空间中随机生成个体的最优个体。

## 3) 非线性能量递减控制策略

在 GJO 中,  $E$  的下降过程是一个线性递减。为避免陷入局部最优, 本文提出非线性能量递减控制策略, 具体表达式如下:

$$E = 1.5E_0(2\text{rand} \times e^{-\frac{0.5\pi t}{t_{\max}}}) \quad (23)$$

## 2.4 算法性能测试

为验证本文所提改进算法的有效性, 选取 6 组测试函数对 PSO、GJO 和 MSGJO 算法进行测试。如附录 A 表 A1 所示为测试函数相关属性。设置种群数量为 30, 最大迭代次数为 500。其中,  $f_1 \sim f_3$  是单峰函数, 用于检验算法的收敛精度;  $f_4 \sim f_6$  是多峰函数, 用于检验算法全局寻优的能力。

各算法运行 30 次结果如附录 A 表 A2 所示, 适应度值如图 B1 所示。单峰测试结果表明, MSGJO 的收敛精度高于 GJO 和 PSO; 多峰测试结果表明, MSGJO 的寻优能力高于 GJO 和 PSO, 且 MSGJO 在函数  $f_1, f_3, f_4$  和  $f_6$  上均达到了理论最优值 0。以此表明, MSGJO 具有更高的收敛精度和优化能力。

## 2.5 误差修正

通过误差修正可以预测误差序列, 从而进一步提高预测精度。误差修正步骤如下:

1) 风电功率实际值用  $f_t$  表示, 预测值用  $y_t$  表示, 误差序列为

$$\varepsilon_t = f_t - y_t \quad (24)$$

2) 将各个 IMF 分量所得误差序列作为新的

序列输入到 MSGJO-LSTM 模型中得到误差预测值  $\varphi_t$ 。

3) 将风电功率预测值  $y_t$  和误差预测值  $\varphi_t$  相加得到最终风功率预测值  $\hat{y}_t$ :

$$\hat{y}_t = y_t + \varphi_t \quad (25)$$

## 2.6 预测模型建立

本文提出 ICEEMDAN-SE-MSGJO-LSTM-EC 组合预测模型, 具体步骤如下, 建模流程图如图 2 所示。

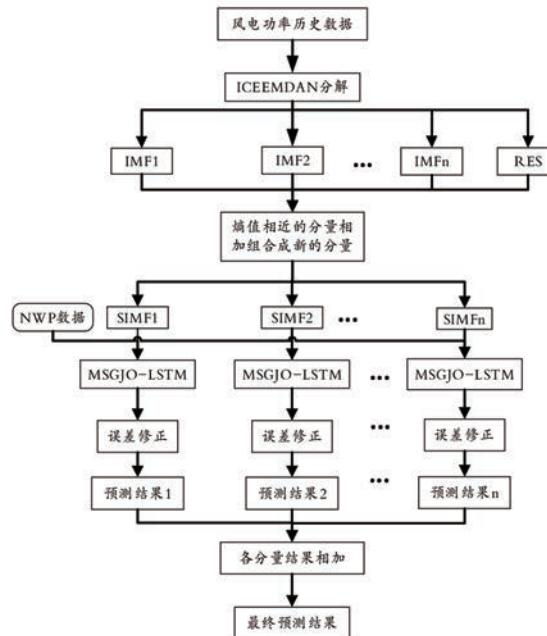


图 2 模型预测流程图

Fig. 2 Model prediction flowchart

1) 通过 ICEEMDAN 对原始风功率数据进行分解得到  $k$  个 IMF 分量和一个残差分量。

2) 计算每个 IMF 分量和残差量的熵值, 将熵值相近的分量相加组合成新的模态分量 SIMF。

3) 对每个模态分量建立 MSGJO-LSTM 模型, 通过 MSGJO 寻优算法对 LSTM 网络的学习率、隐含层神经元个数和训练次数寻优并进行风功率预测。

4) 对每个 SIMF 分量真实值和预测值做差值得到误差序列, 输入到 MSGJO-LSTM 网络中得到误差预测, 与功率预测值相加得到每个模态分量的最终预测值。

5) 将所有模态分量预测值相加得到最终预测值。

6) 对最终预测结果进行误差分析。本文采

用平均绝对误差  $MAE$ 、平均绝对百分比误差  $MAPE$ 、均方根误差  $RMSE$  和决定系数  $R^2$  对模型测评, 计算式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n [ |f_i - \hat{y}_i| ] \quad (26)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left[ \left| \frac{f_i - \hat{y}_i}{f_i} \right| \right] \quad (27)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [f_i - \hat{y}_i]^2} \quad (28)$$

$$R^2 = 1 - \left[ \sum_{i=1}^n (f_i - \hat{y}_i)^2 / \sum_{i=1}^n (f_i - \bar{y}_i)^2 \right] \quad (29)$$

式中:  $f_i$  为原始风功率数据;  $\hat{y}_i$  为最终风功率预测值;  $\bar{y}_i$  为原始风功率数据均值。

### 3 实例分析

#### 3.1 数据处理与分解

本文数据取自 KDD CUP2022 年比赛数据, 选用 1 号风机和 30 号风机各 1440 个数据点, 时间间隔 10 min, 风机额定功率 1 500 kW。数据前 70% 作为训练集, 后 30% 作为测试集。风功率原始数据曲线如图 3 所示。

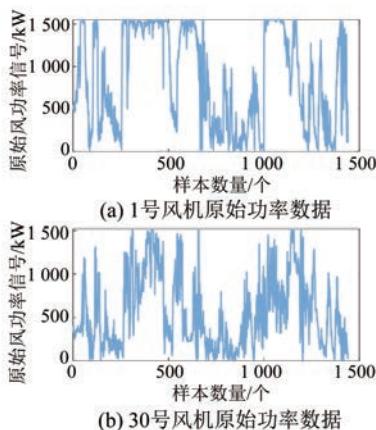


图 3 风功率原始数据

Fig. 3 Raw data of wind power

风功率原始数据经 ICEEMDAN 分解为 9 个 IMF 分量和 1 个残差分量。ICEEMDAN 分解结果如附录 B 图 B2 所示。为了提高预测精度和减少模型训练时间, 对每个 IMF 分量和残差量计算样本熵值, 对熵值相近的量相加组合成新的分量 SIMF。ICEEMDAN-SE 分解结果如附录 B 图 B3 所示。

#### 3.2 预测结果分析

PSO、GJO 和 MSGJO 的目标函数维度为 4, 目标函数为均方误差 MSE 最小; 分别对 LSTM 隐含层神经元层数 (L1、L2)、训练次数 (K) 以及学习率 (lr) 寻优。为验证本文模型的有效性, 将本文模型 ICEEMDAN-SE-MSGJO-LSTM-EC 分别与 BP、SVM、LSTM、ICEEMDAN-LSTM、ICEEMDAN-SE-LSTM、ICEEMDAN-SE-PSO-LSTM、ICEEMDAN-SE-GJO-LSTM 和 ICEEMDAN-SE-MSGJO-LSTM 八个模型做对比试验。预测结果如图 4 所示。

为进一步评价各模型的预测效果, 本文对各模型的平均绝对误差  $MAE$ 、平均绝对百分比误差  $MAPE$ 、均方根误差  $RMSE$  和决定系数  $R^2$  进行分析。各模型评价指标如附录 A 表 A3 所示。

由图 4 和附录 A 表 A3 可以看出, 本文所提模型在 1 号风机和 30 号风机上的  $MAE$ 、 $MAPE$  和  $RMSE$  均为最小值。ICEEMDAN-LSTM 相比于 LSTM, 其预测精度有所提高, 说明对原始风电数据进行模态分解可以有效降低原始数据的波动性, 提高预测精度; MSGJO-LSTM 相比于 GJO-LSTM, 其所有评价指标均有减小, 说明使用改进 GJO 对 LSTM 的超参数优化是有效的, 可避免 GJO 陷入局部最优; MSGJO-LSTM-EC 相比于 MSGJO-LSTM, 其评价指标均有所下降, 说明通过误差修正对误差进行预测可以进一步提高预测精度。

### 4 基于核密度估计的区间预测

#### 4.1 基于核密度估计的误差序列概率分布

由于风电功率误差序列不满足各种常见分布, 所以本文采用核密度估计进行风电功率区间预测。核密度估计不需考虑数据的分布情况, 可直接进行概率分布估计。内核函数使用高斯函数, 核函数表达式为

$$f(e) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{e_i - e}{h}\right) \quad (30)$$

式中:  $h$  为窗宽;  $K(\cdot)$  为核函数。

如图 5 所示为误差概率分布图, 可以看出, 本文使用非参数核密度估计曲线与正态分布函数基本拟合, 整体上非参数核密度估计拟合效果更好。

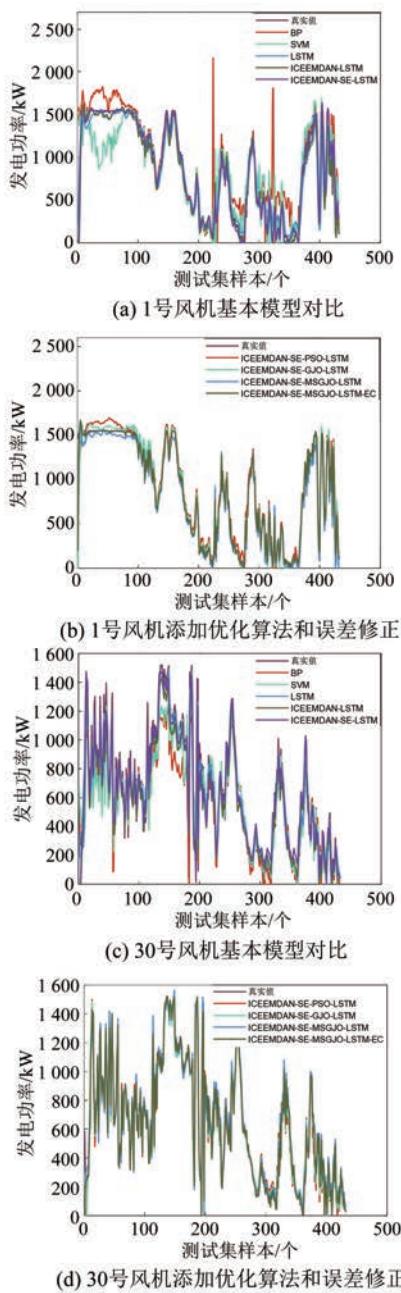


图 4 预测结果图

Fig. 4 Prediction result char

#### 4.2 基于核密度估计的风电功率区间预测

在点预测的基础上, 区间预测通过对风电功率预测误差的概率密度函数进行积分, 得到累计概率密度函数, 通过式(31)计算一定置信概率下的置信区间, 并通过区间覆盖率(PICP)和区间宽度百分比(PIANW)评价区间预测模型。

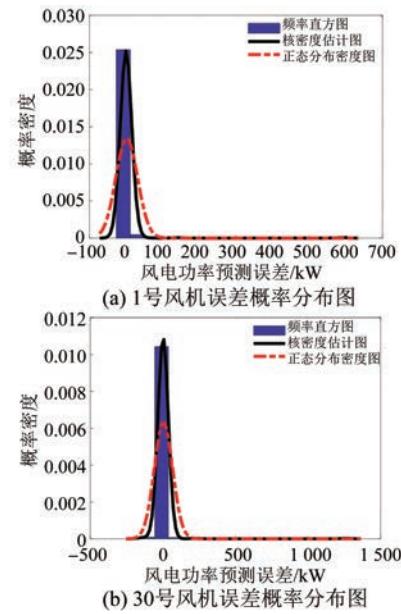


图 5 误差概率分布图

Fig. 5 Error probability distribution diagram

$$\begin{cases} P_{\text{up}} = P + F_{(1-\alpha/2)} \\ P_{\text{low}} = P - F_{(\alpha/2)} \\ P_{\text{interval}} = [P_{\text{up}}, P_{\text{low}}] \end{cases} \quad (31)$$

式中:  $P$  为风功率点预测结果;  $F(\cdot)$  为累计概率分布函数的反函数;  $P_{\text{up}}$  和  $P_{\text{low}}$  分别为风功率区间预测的上边界和下边界。

$$\text{PICP} = \frac{1}{n} \sum_{i=1}^n N_i \quad (32)$$

$$\text{PINAW} = \frac{1}{n} \sum_{i=1}^n (P_{\text{up}} - P_{\text{low}}) \quad (33)$$

式中:  $N_i$  为布尔量, 第  $i$  个风功率点在预测区间内为 1, 不在为 0;  $n$  为风功率数量点。

如图 6 所示为在置信度为 95% 和 90% 下的预测区间结果, 如表 1 所示为不同置信度下的评价指标。

表 1 不同置信度下的评价指标

Tab. 1 Evaluation indicators under different confidence levels

	置信度	PICP/%	PINAW/MW
1 号风机	95%	0.951 4	0.088 4
	90%	0.909 7	0.053 3
30 号风机	95%	0.951 4	0.049 7
	90%	0.902 8	0.035 5

由图 6 可以看出, 基本大部分数据均在预测区间内, 只有极少数前后波动很大的点在预测区

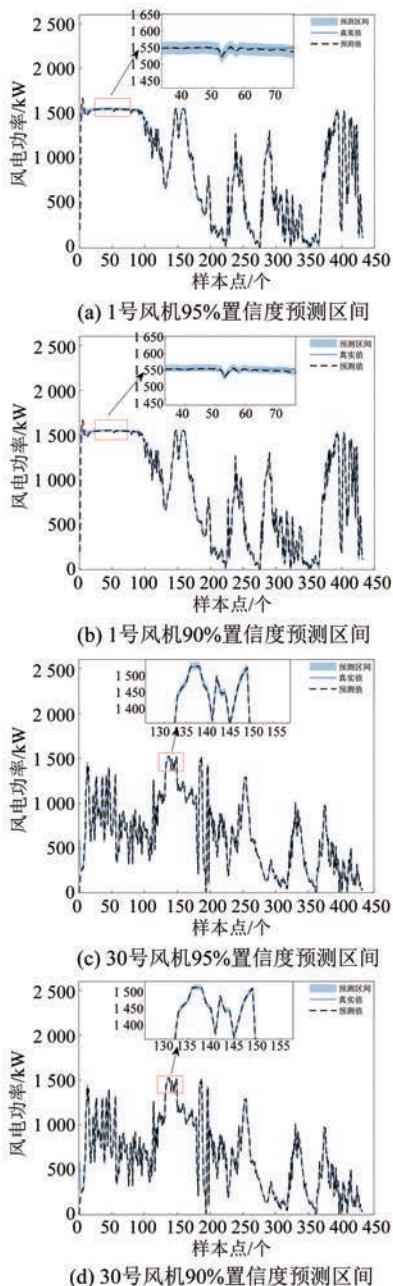


图 6 不同置信度下的区间预测结果

Fig. 6 Interval prediction results under different confidence levels

间之外。由表 1 可知,本文模型覆盖率总体达到置信度要求,区间宽度百分比较窄;随着置信度的增大,区间宽度也在增大,表明真实落在区间内的比例在增大。

## 5 结语

对于风电出力的随机波动性和间歇性,本文提出一种基于 ICEEMDAN-SE-MSGJO-LSTM-EC

的短期风电功率预测模型,得出以下结论:

- 1) 与 BP 模型和 SVM 模型相比,本文使用模型 LSTM 具有更好的预测精度;
- 2) 与单一 LSTM 模型相比,本文使用 ICEEMDAN 模型能把原始数据分解为一系列平缓信号,并且通过样本熵计算将熵值相近的分量相加组合,降低了原始信号的波动性,缩短了模型训练的时间;
- 3) 与 PSO、GJO 算法相比,本文所使用的 MSGJO 算法能有效平衡全局搜索和局部搜索,提高收敛速度;
- 4) 为减少模型的局限性,本文通过对预测结果进行误差修正得到最终预测结果。试验表明经过误差修正能很大程度地弥补模型自身的不足,提高预测精度。

## 参 考 文 献

- [1] 徐询,谢丽蓉,梁武星,等.考虑风电预测误差时序性及风电可信度的双层优化模型[J].电工技术学报,2023,38(6):1620-1632+1661.  
XU X, XIE L R, LIANG W X, et al. Bi-level optimization model considering time series characteristic of wind power forecast error and wind power reliability [J]. Transactions of China Electrotechnical Society, 2023, 38(6): 1620-1632+1661.
- [2] 钱政,裴岩,曹利宵,等.风电功率预测方法综述[J].高电压技术,2016,42(4):1047-1060.  
QIAN Z, PEI Y, CAO L X, et al. Review of wind power forecasting method [J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [3] 乔颖,鲁宗相,闵勇.提高风电功率预测精度的方法[J].电网技术,2017,41(10):3261-3269.  
QIAO Y, LU Z X, MIN Y. Research & application of raising wind power prediction accuracy [J]. Power System Technology, 2017, 41(10): 3261-3269.
- [4] GU J, WANG Y, XIE D, et al. Wind farm nwp data preprocessing method based on t-sne[J]. Energies, 2019, 12(19): 3622-3637.
- [5] 郑婷婷,王海霞,李卫东.风电预测技术及其性能评价综述[J].南方电网技术,2013,7(2):104-109.  
ZHENG T T, WANG H X, LI W D. A review of the wind power forecasting technology and its performance

- evaluation [J]. Southern Power System Technology, 2013, 7(2): 104-109.
- [ 6 ] 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.
- [ 7 ] 吴慧军, 郭超雨, 苏承国, 等. 基于 EEMD-GRU-MC 的短期风功率组合预测方法 [J]. 南方电网技术, 2023, 17(2): 66-73.
- WU H J, GUO C Y, SU C G, et al. Combined prediction method for short-term wind power based on EEMD-GRU-MC [J]. Southern Power System Technology, 2023, 17(2): 66-73.
- [ 8 ] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction [J]. Applied Energy, 2010, 88(4): 1405-1414.
- [ 9 ] AMBACH D, SCHMID W. A new high-dimensional time series approach for wind speed, wind direction and air pressure forecasting [J]. Energy, 2017, 135, 833-850.
- [ 10 ] 王育飞, 付玉超, 孙路, 等. 基于混沌-RBF 神经网络的光伏发电功率超短期预测模型 [J]. 电网技术, 2018, 42(4): 1110-1116.
- WANG Y F, FU Y C, SUN L, et al. Ultra-short term prediction model of photovoltaic output power based on chaos-RBF neural network [J]. Power System Technology, 2018, 42(4): 1110-1116.
- [ 11 ] 徐萌. 基于 MA-SVM 方法的短期光伏功率预测 [J]. 电机与控制应用, 2022, 49(7): 104-111.
- XU M. Short-term photovoltaic power prediction based on MA-SVM method [J]. Electric Machines & Control Application, 2022, 49(7): 104-111.
- [ 12 ] 凌武能, 杭乃善, 李如琦. 基于云支持向量机模型的短期风电功率预测 [J]. 电力自动化设备, 2013, 33(7): 34-38.
- LING W N, HANG N S, LI R Q. Short-term wind power forecasting based on cloud SVM model [J]. Electric Power Automation Equipment, 2013, 33(7): 34-38.
- [ 13 ] 邹金, 朱继忠, 赖旭, 等. 基于时空自回归移动平均模型的风电出力序列模拟 [J]. 电力系统自动化, 2019, 43(3): 101-107.
- ZOU J, ZHU J Z, LAI X, et al. Simulation of wind power output series based on space-time auto-regressive moving average model [J]. Automation of Electric Power Systems, 2019, 43(3): 101-107.
- [ 14 ] TORRES J L, GARCÍAA A, BLAS M D, et al. Forecast of hourly average wind speed with ARMA models in Navarre (Spain) [J]. Solar Energy, 2004, 79(1): 65-77.
- [ 15 ] 丁明, 张立军, 吴义纯. 基于时间序列分析的风场风速预测模型 [J]. 电力自动化设备, 2005(8): 32-34.
- DING M, ZHANG L J, WU Y C. Wind speed forecast model for wind farms based on time series analysis [J]. Electric Power Automation Equipment, 2005(8): 32-34.
- [ 16 ] BARBOSA DE A D, MATTOS A C, LIMAO DE O R C, et al. Different models for forecasting wind power generation: Case study [J]. Energies, 2017, 10(12): 1976.
- [ 17 ] CHEN P, PEDERSEN T, BAK-JENSEN B, et al. ARIMA-based time series model of stochastic wind power generation [J]. IEEE Transactions on Power Systems, 2010, 25(2): 667-676.
- [ 18 ] 江岳春, 张丙江, 邢方方, 等. 基于混沌时间序列 GA-VNN 模型的超短期风功率多步预测 [J]. 电网技术, 2015, 39(8): 2160-2166.
- JIANG Y C, ZHANG B J, XING F F, et al. Super-short-term multi-step prediction of wind power based on GA-VNN model of chaotic time series [J]. Power System Technology, 2015, 39(8): 2160-2166.
- [ 19 ] 李青, 张新燕, 马天娇, 等. 基于 SSA-CNN-BiGRU-Attention 的超短期风电功率预测模型 [J]. 电机与控制应用, 2023, 50(5): 61-71.
- LI Q, ZHANG X Y, MA T J, et al. Ultra-short term forecasting model of wind power based on SSA-CNN-BiGRU-Attention [J]. Electric Machines & Control Application, 2023, 50(5): 61-71.
- [ 20 ] 黄玲玲, 李锁, 符杨, 等. 基于风电机组状态的超短期海上风电功率预测 [J]. 太阳能学报, 2022, 43(8): 391-398.
- HUANG L L, LI S, FU Y, et al. Ultra-short term offshore wind power prediction based on condition-assessment of wind turbines [J]. Acta Energiae Solaris Sinica, 2022, 43(8): 391-398.
- [ 21 ] 张淑清, 杨振宁, 姜安琦, 等. 基于 EN-SKPCA 降维和 FPA 优化 LSTMNN 的短期风电功率预测 [J]. 太阳能学报, 2022, 43(6): 204-211.
- ZHANG S Q, YANG Z N, JIANG A Q, et al. Short term wind power prediction based on EN-SKPCA dimensionality reduction and FPA optimized LSTMNN

- [J]. *Acta Energiae Solaris Sinica*, 2022, 43(6): 204-211.
- [22] 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.
- LI R, MA T, ZHANG X, et al. Short-term wind power prediction based on convolutional long-short-term memory neural network [J]. *Acta Energiae Solaris Sinica*, 2021, 42(6): 304-311.
- [23] 王信宣, 邓斌, 王江. 基于经验模态分解与RBF神经网络的短期风功率预测[J]. 电力系统及其自动化学报, 2020, 32(11): 109-115.
- WANG J X, DENG B, WANG J. Short term wind power prediction based on empirical mode decomposition and RBF neural network [J]. *Proceedings of the CSU-EPSA*, 2020, 32(11): 109-115.
- [24] 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.
- ZHAO Y Y, ZHAO H R, TAN J X, et al. Combined ultra-short-term power prediction for wind power hydrogen production technology [J]. *Acta Energiae Solaris Sinica*, 2023, 44(3): 162-168.
- [25] 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 Q M, LI H Y, WANG Z Q, et al. Short-term wind power forecasting based on LSTM [J]. *Power System Technology*, 2017, 41(12): 3797-3802.
- [26] NITISH C, ANSARI M M. Golden jackal optimization: A novel nature-inspired optimizer for engineering applications [J]. *Expert Systems With Applications*, 2022, 198:116924-116938.
- [27] XIE L, HUAN T, ZHOU H, et al. Tuna swarm optimization: A novel swarm-based metaheuristic algorithm for global optimization [J]. *Computational Intelligence and Neuroscience*, 2021.

---

收稿日期:2023-07-15

收到修改稿日期:2023-08-16

作者简介:

孙瑞星(1998-),男,硕士研究生,研究方向为新能源出力预测,744737537@qq.com;

黄建(1999-),男,硕士研究生,研究方向为电力系统优化调度,1150513831@qq.com;

张江云(2000-),男,硕士研究生,研究方向为电力系统优化调度,1284900085@qq.com;

何超(1995-),男,硕士研究生,研究方向为电力系统优化调度,1826449289@qq.com;

\*通信作者:刘志坚(1975-),男,博士,教授,研究方向为电力系统优化控制、新能源并网稳定,248400248@qq.com。

## Short-Term Wind Power Prediction Based on ICEEMDAN-SE-MSGJO-LSTM-EC

LIU Zhijian\*, SUN Ruixing, HUANG Jian, ZHANG Jiangyun, HE Chao

(Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650000, China)

**Key words:** wind power prediction; error correction; intrinsic computing expressive empirical mode decomposition with adaptive noise (ICEEMDAN); multi-strategy golden jackal optimization (MSGJO); long short-term memory network (LSTM)

With the proposal of the “30 · 60” dual carbon target, accelerating the development and utilization of new energy can greatly reduce the burden on the environment. Wind energy, as a green and renewable energy source, has been widely applied and developed. Due to the randomness, volatility, and intermittency of wind energy, when wind power is connected to the power grid, it causes a huge impact on the stable operation of the power grid. Therefore, accurate prediction of wind power power is of great significance.

This paper constructs a short-term wind power prediction model based on ICEEMDAN-SE-MSGJO LSTM-EC, as shown in Fig.1.

Firstly, in response to the strong volatility and randomness of photovoltaic power generation, ICEEMDAN is used to decompose the original wind power time series into k IMF components and one RES component. Secondly, LSTM prediction model is established for each sequence, and MSGJO optimization algorithm is introduced to optimize the number of neurons, learning rate, training times and other parameters of LSTM model. Thirdly, error correction is applied to the prediction results of each component and the final prediction result is obtained by adding the prediction results of all sequences.

Finally, based on the prediction of the aforementioned

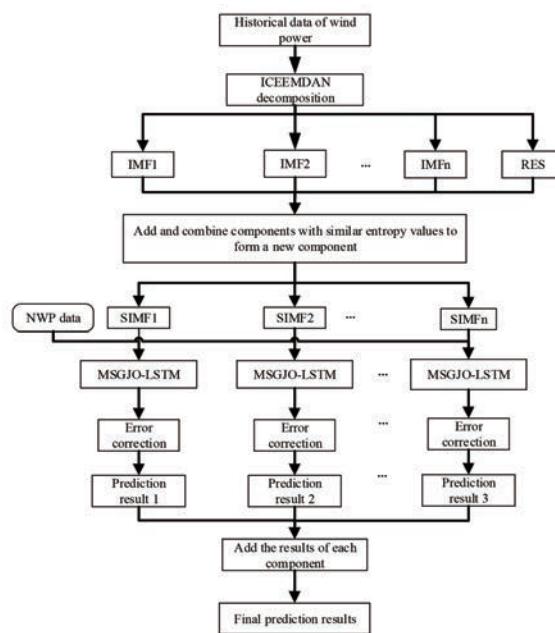


Fig. 1 ICEEMDAN-SE-MSGJO LSTM-EC

points, wind power interval prediction is carried out.

The simulation results of fan 1 are shown in Tab. 1. It can be seen that the improved GJO algorithm proposed in this article has good convergence speed and accuracy; error correction can predict error sequences and improve prediction accuracy; the ICEEMDAN-SE-MSGJO-LSTM-EC model proposed in this article has the best performance.

Tab. 1 Error evaluation index of fan 1 model

fan number	model	MAE/kW	MAPE/%	RMSE/kW	R <sup>2</sup>
fan 1	ICEEMDAN-SE-PSO-LSTM	62.917 9	21.731 5	104.432	0.964 35
	ICEEMDAN-SE-GJO-LSTM	49.219 7	17.000 2	99.017	0.967 95
	ICEEMDAN-SE-MSGJO-LSTM	42.680 4	14.741 6	80.695 6	0.978 72
	ICEEMDAN-SE-MSGJO-LSTM-EC	10.172 1	3.513 4	63.160 7	0.986 96

## Appendix A

**Tab. A1 Test function**

function	expression	dimension	range
Sphere	$f1 = \sum_{i=1}^n x_i^2$	30	[ -100, 100 ]
Schwefel2.22	$f2 = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	30	[ -10, 10 ]
Schwefel1.2	$f3 = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	[ -100, 100 ]
Rastrigin	$f4 = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)] + 10n$	30	[ -5.12, 5.12 ]
Ackley	$f5 = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right] + 20 + e$	30	[ -32, 32 ]
Griewank	$f6 = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	[ -600, 600 ]

**Tab. A2 Test result**

function	optimization algorithm	optimal value	worst value	average value	standard deviation
$f1$	PSO	$7.92 \times 10^{-2}$	$3.42 \times 10^{-1}$	$1.69 \times 10^{-1}$	$5.68 \times 10^{-2}$
	GJO	$1.31 \times 10^{-57}$	$2.34 \times 10^{-53}$	$2.04 \times 10^{-54}$	$5.14 \times 10^{-54}$
	MSGJO	0	$1.20 \times 10^{-240}$	$4.01 \times 10^{-242}$	0
$f2$	PSO	1.641 8	6.352 3	3.478 9	1.121 6
	GJO	$7.22 \times 10^{-34}$	$1.08 \times 10^{-31}$	$1.87 \times 10^{-32}$	$2.15 \times 10^{-32}$
	MSGJO	$6.23 \times 10^{-178}$	$3.36 \times 10^{-128}$	$1.12 \times 10^{-129}$	$6.13 \times 10^{-129}$
$f3$	PSO	11.090 1	55.821 6	29.443 8	12.092 8
	GJO	$2.56 \times 10^{-21}$	$1.69 \times 10^{-16}$	$1.02 \times 10^{-17}$	$3.27 \times 10^{-17}$
	MSGJO	0	$9.18 \times 10^{-240}$	$3.11 \times 10^{-241}$	0
$f4$	PSO	26.931 2	80.798 2	50.421 5	14.516 6
	GJO	0	0	0	0
	MSGJO	0	0	0	0
$f5$	PSO	2.676 2	6.777 7	4.490 5	0.924 4
	GJO	$4.44 \times 10^{-15}$	$7.99 \times 10^{-15}$	$6.93 \times 10^{-15}$	$1.66 \times 10^{-15}$
	MSGJO	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$	0
$f6$	PSO	14.761 2	46.339 8	26.139 7	6.723 0
	GJO	0	0	0	0
	MSGJO	0	0	0	0

**Tab. A3 Error evaluation indicators for each model**

fan number	model	MAE/kW	MAPE/%	RMSE/kW	$R^2$
fan 1	BP	127.414 3	44.008 2	224.502 8	0.835 26
	SVM	125.882 2	43.479	184.561 5	0.888 66
	LSTM	111.557 7	38.531 4	171.271 8	0.904 12
	ICEEMDAN-LSTM	74.196 4	25.627	158.238 8	0.918 16
	ICEEMDAN-SE-LSTM	63.384 4	21.892 6	139.930 8	0.936
	ICEEMDAN-SE-PSO-LSTM	62.917 9	21.731 5	104.432	0.964 35
	ICEEMDAN-SE-GJO-LSTM	49.219 7	17.000 2	99.017	0.967 95
	ICEEMDAN-SE-MSGJO-LSTM	42.680 4	14.741 6	80.695 6	0.978 72
	ICEEMDAN-SE-MSGJO-LSTM-EC	10.172 1	3.513 4	63.160 7	0.986 96
fan 30	BP	103.443 1	35.728 7	150.835 4	0.857 06
	SVM	92.921 1	32.094 4	128.862 4	0.895 67
	LSTM	77.357 6	26.718 9	115.881 7	0.915 63
	ICEEMDAN-LSTM	73.034 8	25.225 8	95.777 5	0.942 37
	ICEEMDAN-SE-LSTM	63.806 3	22.038 4	89.172 6	0.950 04
	ICEEMDAN-SE-PSO-LSTM	42.722 7	14.756	63.925 5	0.974 33
	ICEEMDAN-SE-GJO-LSTM	39.533 1	13.654 5	58.399 5	0.978 57
	ICEEMDAN-SE-MSGJO-LSTM	30.689 6	10.6	46.726 3	0.986 28
	ICEEMDAN-SE-MSGJO-LSTM-EC	5.146 7	1.777 6	29.657 5	0.994 47

## Appendix B

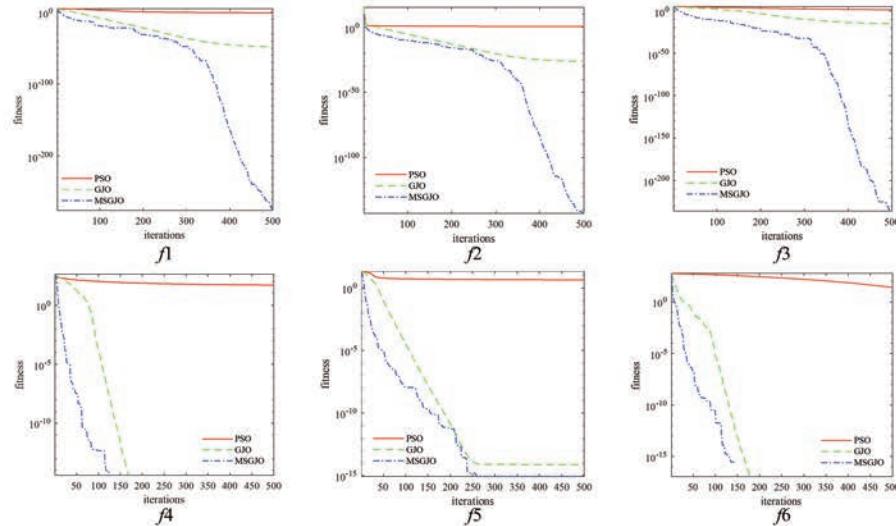


Fig. B1 Function convergence curve

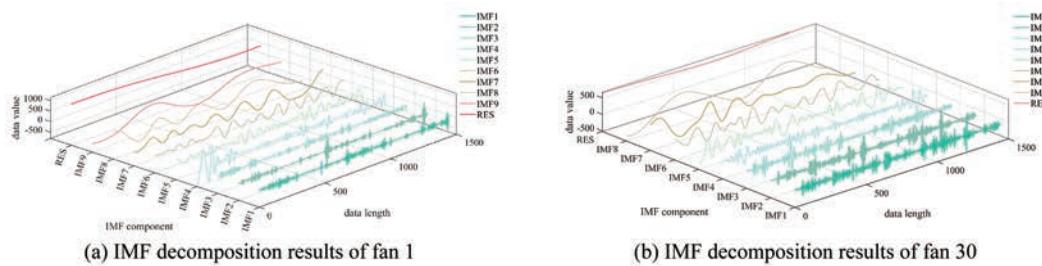


Fig. B2 ICEEMDAN decomposition result diagram

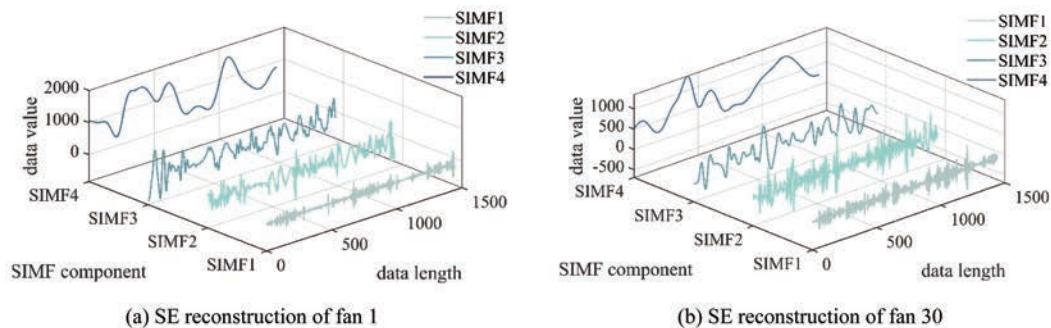


Fig. B3 ICEEMDAN-SE decomposition result diagram