

DOI: 10.19783/j.cnki.pspc.220140

# 基于 VMD-ISSA-KELM 的短期光伏发电功率预测

商立群<sup>1</sup>, 李洪波<sup>1</sup>, 侯亚东<sup>1</sup>, 黄辰浩<sup>1</sup>, 张建涛<sup>1</sup>, 杨雷<sup>2</sup>

(1. 西安科技大学电气与控制工程学院, 陕西 西安 710054; 2. 国网陕西省电力公司渭南供电公司, 陕西 渭南 714000)

**摘要:** 针对光伏发电功率存在随机性和波动性较强、预测精度较低的问题, 提出了一种基于变分模态分解 (variational mode decomposition, VMD) 和改进松鼠觅食算法优化核极限学习机 (improved squirrel search algorithm optimization kernel extreme learning machine, ISSA-KELM) 的预测模型。首先, 利用高斯混合模型 (Gaussian mixture model, GMM) 将光伏发电功率数据进行聚类, 得到不同天气类型下的相似日样本。其次, 利用 VMD 对原始光伏发电功率序列进行平稳化处理, 得到若干个规律性较强的子序列。然后, 对不同子序列构建 KELM 预测模型, 并使用 ISSA 优化 KELM 的核参数和正则化系数。最后, 将不同子序列的预测值进行重构, 得到最终预测结果。结合实际算例, 结果表明: 所提出的 VMD-ISSA-KELM 模型在不同天气条件下均能得到满意的预测精度, 且明显优于其他模型, 验证了其有效性和优越性。

**关键词:** 光伏发电; 短期功率预测; 相似日; 高斯混合模型; 变分模态分解; 改进松鼠觅食算法; 核极限学习机

## Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM

SHANG Liqun<sup>1</sup>, LI Hongbo<sup>1</sup>, HOU Yadong<sup>1</sup>, HUANG Chenhao<sup>1</sup>, ZHANG Jiantao<sup>1</sup>, YANG Lei<sup>2</sup>

(1. College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China;

2. Weinan Power Supply Company, State Grid Shaanxi Electric Power Company, Weinan 714000, China)

**Abstract:** There is a problem of a strong randomness, volatility and low prediction accuracy for photovoltaic power generation. Thus a prediction model based on variational mode decomposition (VMD) and an improved squirrel search algorithm optimization kernel extreme learning machine (ISSA-KELM) is proposed. First, photovoltaic power data is clustered using a Gaussian mixture model to obtain similar samples under different weather types. Second, the original photovoltaic power generation power sequence is stabilized using VMD to obtain a number of regular subsequences. Then, the KELM prediction model is constructed for different subsequences and ISSA is used to optimize nuclear and regularization parameters of the KELM. Finally, the predicted value of different subsequences is reconstructed to obtain the final prediction result. Combined with an actual example, the results show that the proposed VMD-ISSA-KELM model can obtain satisfactory prediction accuracy in different weather conditions, and is significantly better than other models, verifying its effectiveness and superiority.

This work is supported by the Natural Science Basic Research Program of Shaanxi Province (No. 2021JM-393).

**Key words:** photovoltaic power generation; short-term power prediction; similar day; Gaussian mixture model; variational mode decomposition; improved squirrel search algorithm; kernel extreme learning machine

## 0 引言

近年来, 世界正面临着紧急的气候变化和能源枯竭问题。在许多国家, 可再生能源逐渐取代了传统的化石燃料能源<sup>[1-2]</sup>。作为最受欢迎的可再生能源

之一, 太阳能安全高效且经济环保, 具有丰富的资源优势。目前, 太阳能发电主要分为太阳能热发电和光伏发电, 其中光伏发电以相对快的速度逐年增长。由于光伏发电系统会受昼夜交替和外界气象条件的影响, 因此光伏发电功率具有较强的随机性、波动性和不确定性<sup>[3-4]</sup>。在高比例光伏接入电网之后, 增大了电网调度的难度和复杂度, 对电力系统的安全稳定运行造成巨大挑战<sup>[5-6]</sup>。准确可靠的光伏

基金项目: 陕西省自然科学基金基础研究计划项目资助 (2021JM-393)

发电功率预测对提高光伏电站接入电网的比例、制定合理的调度计划以及实现电力系统安全稳定运行具有重要意义<sup>[7-8]</sup>。

目前短期光伏发电功率预测方法主要有 3 大类: 物理模型法、统计分析法和组合预测法<sup>[9-11]</sup>。物理模型法主要通过太阳辐照传递方程进行预测, 不需要大量的历史数据, 但其对光伏电站地理信息以及气象数据可靠性要求较高, 且易受外界条件的影响, 抗干扰能力差, 而统计分析法主要是基于预测模型输入和输出因素之间的映射建立统计规律进行预测, 因此需要大量的历史数据来获取其中的规律<sup>[12-13]</sup>。近年来, 以神经网络(artificial neural network, ANN)和支持向量回归(support vector regression, SVR)为代表的智能统计分析模型已广泛应用于光伏发电功率预测领域。核极限学习机(kernel extreme learning machine, KELM)是一种新型人工智能预测模型, 它是在极限学习机(extreme learning machine, ELM)的基础上引入了核函数思想, 进而有效克服了 ELM 因随机生成初始权值和阈值导致输出稳定性低下的问题, 提高了输出稳定性, 但其预测性能通常受参数选择的影响<sup>[14]</sup>, 利用启发式算法优化模型参数具有明显优势。常见的启发式优化算法有遗传算法<sup>[15]</sup>、粒子群算法<sup>[16]</sup>、萤火虫算法<sup>[17]</sup>等。松鼠觅食算法(sparrow search algorithm, SSA)于 2018 年首次提出<sup>[18]</sup>, 该算法能够求解具有约束和未知搜索空间的复杂问题, 相较于其他优化算法, 在全局搜索能力和寻优精度等方面具有显著优势, 但其易陷入局部最优的缺点仍然存在, 因此引入反向学习机制和  $t$  分布变异机制得到松鼠觅食算法(improved sparrow search algorithm, ISSA), 本文拟采用 ISSA 对 KELM 的参数进行寻优。

单一的人工智能预测模型在一定程度上受自身特性的限制, 不能取得较好的预测结果, 基于多种预测模型结合的组合预测法能够获得各单一预测模型的优点, 进而有效提高预测精度, 因此组合预测法得到了国内外学者的广泛关注。组合预测法一般包括权重组合法和分解组合法。对于光伏发电功率而言, 由于其具有较强的随机性和波动性, 直接使用原始光伏数据进行预测往往难以获得较高的精度, 因此基于原始光伏序列分解并预测的组合方法优势更为显著<sup>[19-20]</sup>。分解组合法是利用分解技术对光伏发电功率序列进行平稳化处理, 对得到的若干个子序列分别建模预测并重构, 从而得到精度更高的预测结果。常见的分解技术有经验模态分解(empirical mode decomposition, EMD)、集成经验模态分解(ensemble empirical mode decomposition, EEMD)和变

分模态分解(variational mode decomposition, VMD)等<sup>[21-23]</sup>。文献[24-25]分别利用 EMD 和 EEMD 对光伏发电功率序列进行分解, 对子序列分别建模预测得到最终的结果, 获得了较高的预测精度, 但 EMD 及其改进方法均存在明显模态混叠的现象, 在一定程度上会影响模型的预测性能。VMD 是一种完全非递归自适应的分解技术, 它能够分解成若干个可反映原始信号局部特征的规律性较强的模态分量, 在测量噪声和避免模态混叠现象方面具有明显优势<sup>[26]</sup>。鉴于以上 VMD 的优点, 本文拟采用 VMD 对光伏发电功率进行分解处理。

本文提出了一种 VMD-ISSA-KELM 的预测模型。首先, 为了得到更好的光伏发电功率样本集, 利用 GMM 对数据进行聚类, 进而得到不同天气类型下的相似日样本; 其次, 针对光伏发电功率具有较强的波动性和随机性, 利用 VMD 对原始光伏发电功率序列进行平稳化处理, 得到若干个规律性较强的子序列; 然后, 对不同子序列建立 KELM 模型, 并利用 ISSA 对 KELM 参数进行寻优; 最后, 对子序列的预测值进行重构, 得到最终预测结果。与 SVR、KELM、EEMD-KELM、VMD-KELM、VMD-ISSA-KELM 模型进行对比, 并通过实例数据验证了所提 VMD-ISSA-KELM 模型的有效性和优越性。

## 1 相似日选取

### 1.1 气象因素相关性分析

斯皮尔曼相关系数(spearman correlation coefficient, SCC)是一种衡量特征向量和目标向量之间相关程度的统计指标。相较于皮尔逊相关系数(spearman correlation coefficient, PCC), SCC 无需对数据进行正态性检验, 适用范围更广, 能够更好地表现两者间的相关程度。与 PCC 不同, SCC 计算采用的数据为“秩”, 即根据向量数值的排序等级而非数值本身, 具体表达式为

$$\rho_s = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (1)$$

式中:  $N$  为样本数;  $X_i$  为气象因素等级数, 如温度、辐照度、相对湿度、风速等;  $Y_i$  为光伏发电功率等级数;  $\bar{X}$  和  $\bar{Y}$  分别为某气象因素与光伏发电功率的平均等级数。

$\rho_s$  取值介于 -1 和 1 之间。若  $\rho_s > 0$  则表示两者呈现正相关, 否则呈现负相关。 $\rho_s$  的绝对值越接近 1, 则表示两者相关程度越强, 反之越低。使用

澳大利亚太阳能研发中心某光伏电站的实测数据进行相关性分析,其中气象因素包括温度、相对湿度、水平辐射、散射、风速及风向。气象因素和光伏发电功率间的 SCC 如表 1 所示。

表 1 光伏发电功率与气象因素间的相关系数

Table 1 SCC between photovoltaic power generation and meteorological factors

| 因素   | 散射   | 温度   | 相对湿度  | 水平辐射 | 风速   | 风向    |
|------|------|------|-------|------|------|-------|
| 相关系数 | 0.81 | 0.45 | -0.11 | 0.96 | 0.28 | -0.03 |

由表 1 可知,水平辐射和散射与光伏发电功率 SCC 分别为 0.96 和 0.81,具有强相关性;紧随其后的是温度和风速,而相对湿度和风向几乎没有相关性,因此将水平辐射、散射、风速和温度等 4 个相关度强的气象因素作为输入特征。

### 1.2 高斯混合模型选取相似日

GMM 是一种基于概率理论的聚类方法,其基本原理为:假设样本集服从  $K$  个参数未知的高斯分布,利用期望最大化(expectation maximization, EM)算法对不同高斯分布进行参数估计,得到高斯混合模型,并将服从同一分布的样本集分为一类,从而实现聚类。传统的层次聚类、模糊聚类等方法过于依赖起始点和距离的度量,而 GMM 聚类只需根据概率分配聚类,且能够更好地捕获属性之间的相关性和依赖性<sup>[27]</sup>,因此本文采用 GMM 聚类方法对光伏功率相似日进行选择。算法具体过程如下。

1) 假设 GMM 聚类个数为  $K$ ,随机初始化参数均值  $\mu_0$ 、协方差  $\Sigma_0$  和权重  $\omega_0$ 。

2) EM 算法分为期望步(E-step)和最大化步(M-step)。利用 E-step 计算每个样本点  $z_i$  属于第  $k$  个分布的概率,表达式为

$$\gamma_k(z_i) = \frac{\omega_k N(z_i | \mu_k, \Sigma_k)}{\sum_{k=1}^K \omega_k N(z_i | \mu_k, \Sigma_k)} \quad (2)$$

式中:  $N(z_i | \mu_k, \Sigma_k)$  为高斯概率密度函数;  $\mu_k$ 、 $\Sigma_k$ 、 $\omega_k$  分别为第  $k$  个分布的均值、协方差和权重。

3) 利用 M-step 求解每个分布的参数并更新,表达式为

$$\mu_k = \frac{\sum_{i=1}^N \gamma_k(z_i) x_i}{\sum_{i=1}^N \gamma_k(z_i)} \quad (3)$$

$$\Sigma_k = \frac{\sum_{i=1}^N \gamma_k(z_i) (z_i - \mu_k)(z_i - \mu_k)^T}{\sum_{i=1}^N \gamma_k(z_i)} \quad (4)$$

$$\omega_k = \frac{1}{N} \sum_{i=1}^N \gamma_k(z_i) \quad (5)$$

4) 重复步骤 2) 和 3),直至参数收敛。

5) 获得高斯混合模型,并最终将样本点聚类。

为了获得聚类特征向量,将均值和标准差作为特征指标,并将相关度强的 4 个气象因素和光伏历史功率转化为日特征指标,则聚类特征向量可记为  $\mathbf{X}_j = [X_{j,1}, X_{j,2}, \dots, X_{j,10}] (j=1, 2, \dots, N)$ ,本文采用贝叶斯信息准则(bayesian information criterion, BIC)<sup>[28]</sup>确定 GMM 最佳聚类数为 3,并根据光伏功率波动特点分为晴天、多云、雨天 3 种天气类型,由此建立光伏功率相似日样本。

## 2 预测模型相关原理

### 2.1 变分模态分解

VMD 是一种非平稳信号自适应分解算法,其主要原理是利用各个模态均存在着中心频率带宽,当模态分量带宽之和取最小值时,则原始信号分解成一系列具有特定带宽的本征模态分量。算法具体过程如下。

1) 将原始信号  $f$  分解为  $K$  个有限带宽模态函数,并采用希尔伯特变换对每个模态函数  $u_k(t)$  进行信号解析,得到单边频谱。

2) 每个模态函数  $u_k(t)$  中加入指数项对中心频率  $\omega_k$  进行修正,并将每个模态的频谱调制至基频带宽。

3) 通过计算解调信号的梯度二范数估计每个模态函数  $u_k(t)$  的基频带宽,构建带约束条件的变分模型如式(6)。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \partial_t \left\| \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k u_k = f \end{cases} \quad (6)$$

式中:  $\{u_k\}$  和  $\{\omega_k\}$  分别为模态集合和中心率集合;  $\partial_t$  为偏导运算符;  $*$  为卷积运算符;  $\delta(t)$  为单位脉冲函数。

4) 为了将问题转化为非约束条件的变分模型,进而简化计算,引入 Lagrange 算子  $\lambda(t)$  和二次惩罚项  $\alpha$  可得扩展后的 Lagrange 表达式,如式(7)所示。

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (7)$$

5) 采用交替方向乘子法计算扩展的 Lagrange 表达式的“鞍点”, 并更新  $u_k^{n+1}$ 、 $\omega_k^{n+1}$ , 直至获得变分模型的优解。更新表达式为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (8)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^{n+1}(\omega)| d\omega}{\int_0^\infty |u_k^{n+1}(\omega)| d\omega} \quad (9)$$

式中:  $\hat{u}_k^{n+1}(\omega)$  为当前剩余量  $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega)$  的维纳滤波;  $\omega_k^{n+1}$  为当前模态函数功率谱的中心频率;  $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}(\omega)$  和  $u_k^{n+1}(\omega)$  分别为  $f(t)$ 、 $u(t)$ 、 $\lambda(t)$  和  $\hat{u}_k^{n+1}(t)$  的傅里叶变换。

## 2.2 核极限学习机

KELM 是在传统 ELM 的基础上延展而来, 用核映射代替随机映射, 进而将高复杂低维的空间问题转化为高维空间内积运算问题, 相较于 ELM 具有更强的网络输出稳定性和泛化能力。

对于  $N$  组不同的样本  $\{(\mathbf{x}_i, t_i)\}_{i=1}^N$ , 当 ELM 隐含层节点数为  $M$ , 激励函数为  $g(\cdot)$  时, 其表达式为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (10)$$

$$\mathbf{H} = \begin{bmatrix} g(\omega_1 \mathbf{x}_1 + b_1) & \mathbf{L} & g(\omega_M \mathbf{x}_1 + b_M) \\ \mathbf{M} & & \mathbf{M} \\ g(\omega_1 \mathbf{x}_N + b_1) & \mathbf{L} & g(\omega_M \mathbf{x}_N + b_M) \end{bmatrix}_{N \times M} \quad (11)$$

式中:  $\mathbf{H}$  为隐含层输出矩阵;  $\boldsymbol{\beta}$  为输出权值矩阵;  $\mathbf{T}$  为目标输出矩阵。

ELM 学习过程可等价于利用最小二乘法求最优解。为提高模型的稳定性和泛化能力, 引入正则化系数  $C$ , 求得最小二乘解, 即

$$\boldsymbol{\beta}^* = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T (\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1} \mathbf{T} \quad (12)$$

式中,  $\mathbf{H}^+$  为  $\mathbf{H}$  的广义逆。

根据 Mercer's 条件, 定义核矩阵为

$$\begin{cases} \boldsymbol{\Omega} = \mathbf{H}\mathbf{H}^T \\ \boldsymbol{\Omega}_{(i,j)} = \mathbf{h}(\mathbf{x}_i) \mathbf{h}(\mathbf{x}_j) = \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) \end{cases} \quad (13)$$

式中,  $\mathbf{K}(\cdot)$  为核函数, 本文选择高斯核函数, 即

$$\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{g^2}\right) \quad (14)$$

式中,  $g$  为核参数。

可得 KELM 的预测输出函数为

$$\mathbf{y}(\mathbf{x}) = \mathbf{h}(\mathbf{x})\boldsymbol{\beta}^* = \mathbf{h}(\mathbf{x})\mathbf{H}^T (\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1} \mathbf{T} = \begin{bmatrix} \mathbf{K}(\mathbf{x}, \mathbf{x}_1) \\ \mathbf{M} \\ \mathbf{K}(\mathbf{x}, \mathbf{x}_M) \end{bmatrix} (\boldsymbol{\Omega} + \frac{\mathbf{I}}{C})^{-1} \mathbf{T} \quad (15)$$

式中,  $\mathbf{I}$  为单位矩阵。

综上可知, 核参数  $g$  和正则化系数  $C$  是影响 KELM 预测性能的重要因素。

## 2.3 松鼠觅食算法及其改进

### 2.3.1 松鼠觅食算法

松鼠觅食算法是一种新型的启发式算法, 其主要模拟了自然界中松鼠在树林间滑行并觅食的过程。设松鼠种群数量为  $N$ , 在  $d$  维空间内搜索, 则第  $i$  只松鼠的位置为  $\mathbf{x}_i = [x_{i,1}, x_{i,2}, \mathbf{L}, x_{i,d}]$ 。算法描述如下。

1) 松鼠位置初始化, 计算适应度值, 升序排列并分类。其中适应度值最小的松鼠  $\mathbf{X}_{nt}$  在核桃树上, 适应度值较小的 3 只松鼠  $\mathbf{X}_{at}$  在橡树上, 其余的松鼠  $\mathbf{X}_{mt}$  均在普通树上。

2) 松鼠更新位置和适应度值。松鼠种群有 3 种不同的觅食方式: 普通树上的松鼠  $\mathbf{X}_{mt}$  向橡树上移动; 普通树上的松鼠  $\mathbf{X}_{mt}$  向核桃树上移动; 橡树上的松鼠  $\mathbf{X}_{at}$  向核桃树上移动。更新位置表达式如式 (16)~式 (18) 所示。

$$\mathbf{X}_{nt}^{t+1} \begin{cases} \mathbf{X}_{nt}^t + d_g \times G_c \times (\mathbf{X}_{at}^t - \mathbf{X}_{nt}^t), & R_1 \geq P_{dp} \\ \mathbf{r}_{\text{and}}, & R_1 < P_{dp} \end{cases} \quad (16)$$

$$\mathbf{X}_{mt}^{t+1} \begin{cases} \mathbf{X}_{mt}^t + d_g \times G_c \times (\mathbf{X}_{ht}^t - \mathbf{X}_{mt}^t), & R_2 \geq P_{dp} \\ \mathbf{r}_{\text{and}}, & R_2 < P_{dp} \end{cases} \quad (17)$$

$$\mathbf{X}_{at}^{t+1} \begin{cases} \mathbf{X}_{at}^t + d_g \times G_c \times (\mathbf{X}_{ht}^t - \mathbf{X}_{at}^t), & R_3 \geq P_{dp} \\ \mathbf{r}_{\text{and}}, & R_3 < P_{dp} \end{cases} \quad (18)$$

式中:  $t$  为当前迭代次数;  $d_g$  为随机滑动距离, 用于平衡寻优区间;  $G_c$  为滑行常数;  $P_{dp}$  为捕食者出现的概率;  $R_1$ 、 $R_2$ 、 $R_3$  均为区间 [0,1] 上服从均匀分布的随机数。

3) 考虑季节变化对松鼠觅食行为的影响, 引入季节监控条件, 表达式为

$$S_c^t = \sqrt{\sum_{k=1}^d (\mathbf{X}_{at,k}^t - \mathbf{X}_{ht,k}^t)^2} \quad t=1,2,3 \quad (19)$$

$$S_{\min} = \frac{10e^{-6}}{365^{2.5t/T_{\max}}} \quad (20)$$

式中:  $S_c^t$  为季节常数;  $S_{\min}$  为季节常数最小值。当满足  $S_c^t < S_{\min}$  时, 表示冬季结束, 普通的松鼠无法

在树林中寻找食物，于是进行随机迁移，更新表达式为

$$\mathbf{X}_m^{\text{new}} = \mathbf{b}_l + l_{\text{evy}} \times (\mathbf{b}_u - \mathbf{b}_l) \quad (21)$$

式中： $\mathbf{b}_u$ 、 $\mathbf{b}_l$ 分别为松鼠觅食范围的上界与下界； $l_{\text{evy}}$ 表示列维飞行，它是一种随机改变步长的方法，能提高松鼠的觅食能力，具体表达式为

$$\begin{cases} l_{\text{evy}} = 0.01 \times r_a \times \sigma / (|r_b|^{1/\beta}) \\ \sigma = \left[ \frac{\Gamma(1+\beta) \times \sin(\frac{\pi\beta}{2})}{\Gamma(\frac{1+\beta}{2}) \times \beta \times 2^{(\beta-1)/2}} \right]^{1/\beta} \end{cases} \quad (22)$$

式中： $r_a$ 、 $r_b$ 均为区间[0,1]上服从均匀分布的随机数； $\beta$ 为常数，通常取1.5； $\Gamma(x) = (x-1)!$ 。

松鼠种群通过3种不同位置更新方式，并监控季节变化，不断迭代更新，直到达到最大迭代次数或精度的要求，最终输出全局最优解(在核桃树上的松鼠)。

### 2.3.2 松鼠觅食算法的改进

由于基本的松鼠算法存在收敛速度慢、易陷入局部最优等缺点，将反向学习机制和 $t$ 分布变异融入到算法之中，进而提高算法的寻优能力。

反向学习机制<sup>[29]</sup>是以当前解为基础，利用反向学习机制寻得反向解，与当前解进行比较，并保留更优解的一种方法。为了使松鼠个体具有更好的搜索能力，将反向学习机制融入到松鼠觅食算法中。

反向学习机制表达式为

$$\begin{cases} \mathbf{X}_{\text{bestback}}^{\%} = \mathbf{b}_u + \mathbf{r}_{\text{and}} \times (\mathbf{b}_l - \mathbf{X}_{\text{best}}^t) \\ \mathbf{X}^{t+1} = \mathbf{X}_{\text{bestback}}^{\%} + b \times (\mathbf{X}_{\text{best}}^t - \mathbf{X}_{\text{bestback}}^{\%}) \\ b = (T_{\text{max}} - t / T_{\text{max}})^t \end{cases} \quad (23)$$

式中： $\mathbf{X}_{\text{best}}^t$ 为当前最优解； $\mathbf{X}_{\text{bestback}}^{\%}$ 为当前最优解的反向解； $\mathbf{r}_{\text{and}}$ 为[0,1]之间随机数组成的 $1 \times d$ 的矩阵； $b$ 为控制系数。

$t$ 分布又称为学生分布，它是数学理论中的重要分布，通过分布函数对算法进行扰动又可称为分布变异。 $t$ 分布变异综合了柯西分布变异与高斯分布变异的优点，在算法初期有良好的全局搜索能力，后期具有较强的局部开发能力<sup>[30]</sup>。因此融入 $t$ 分布变异机制来对松鼠种群的位置进行更新，发挥 $t$ 分布的扰动优势，提高算法的寻优能力。 $t$ 分布变异机制定义为

$$\mathbf{X}^{t+1} = \mathbf{X}_{\text{best}}^t + \mathbf{X}_{\text{best}}^t \times t(i_{\text{ter}}) \quad (24)$$

式中， $t(i_{\text{ter}})$ 为以算法的迭代次数 $i_{\text{ter}}$ 作为自由度参

数的 $t$ 分布变异扰动。

为了使反向学习机制和 $t$ 分布变异机制能够有效的配合，采用文献[31]提出的一种动态位置更新策略，将反向学习机制和 $t$ 分布变异机制根据一定的概率交替进行，提高算法寻优能力。选择概率 $P_s$ 的表达式为

$$P_s = -\exp(1 - t / T_{\text{max}})^{20} + \theta \quad (25)$$

式中， $\theta$ 为调节参数。产生一个随机数 $r_{\text{and}}$ ，若 $r_{\text{and}} < P_s$ ，则根据式(23)利用反向学习机制对松鼠位置进行更新，否则根据式(24)利用 $t$ 分布变异机制对目标位置进行更新。

### 2.4 改进松鼠觅食算法优化核极限学习机

KELM预测性能受核参数 $g$ 和正则化系数 $C$ 的影响。在KELM训练学习过程中，核参数 $g$ 具有调节经验风险比例和置信区间的作用，而正则化系数 $C$ 用于控制训练误差所占比例的范围，若核参数和正则化系数选择不当，则会使KELM的泛化能力大大减弱，从而导致网络输出不稳定，因此对KELM的核参数和正则化系数进行优化十分必要。

本文采用ISSA算法对KELM关键参数进行寻优，得到核参数和正则化系数最优参数组合 $(g, C)$ ，详细优化过程如下。

1) 初始化参数和种群。参数包括松鼠种群数量 $N$ 、种群维度 $D$ 、最大迭代次数 $T_{\text{max}}$ ，滑行常数 $G_c$ ，捕食者出现的概率 $P_{dp}$ ，搜索范围上下界 $[b_u, b_l]$ 。

2) 计算松鼠个体适应度值。本文将训练集中预测值与实际值的均方误差作为适应度函数，将适应度值升序排列，并根据适应度的优劣确定3种不同类型的松鼠位置。

3) 更新松鼠个体的位置和适应度值，根据式(16)一式(18)更新不同类型松鼠位置和适应度值。

4) 根据季节变化条件更新松鼠个体的位置和适应度值。若满足 $S'_c < S_{\text{min}}$ ，则普通树上的松鼠根据式(21)更新位置，其余两种类型的松鼠位置不变，否则松鼠位置不变。

5) 融入反向学习机制和 $t$ 分布变异机制。根据式(25)得到一个选择概率 $P_s$ ，同时产生一个随机数 $r_{\text{and}}$ ，若 $r_{\text{and}} < P_s$ ，则根据式(23)更新松鼠位置，否则根据式(24)更新松鼠位置。

6) 更新松鼠个体的位置和适应度值，判断是否达到最大迭代次数，若是则输出最优解，否则返回2)。

7) 将得到的结果输入到KELM。

整体优化流程如图1所示。

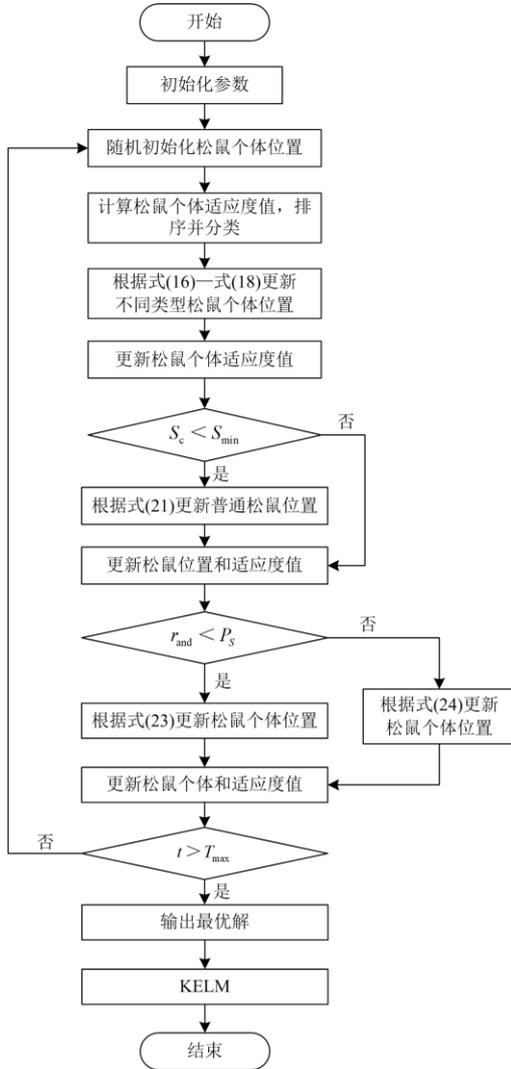


图 1 ISSA-KELM 流程

Fig. 1 Flow chart of ISSA-KELM

### 3 基于 VMD-ISSA-KELM 的短期光伏发电功率预测模型

基于 VMD-ISSA-KELM 的短期发电功率预测流程如图 2 所示, 具体步骤如下。

1) 首先对光伏发电功率原始数据进行预处理, 对异常值进行修正和替换, 同时对数据集进行划分, 确定训练集和测试集;

2) 利用 SCC 对气象因素进行相关性分析, 同时建立聚类特征向量; 利用 GMM 聚类方法对光伏发电功率进行相似日选取, 得到 3 种天气类型的相似日样本。

3) 采用 VMD 算法对不同天气类型的相似日样本分解为不同频率尺度的光伏功率子序列 [IMF1, IMF2, L, IMFK];

- 4) 对各子序列分别建立 KELM 预测模型;
- 5) 利用 ISSA 对 KELM 的参数进行寻优, 建立 ISSA-KELM 预测模型;
- 6) 将不同子序列预测结果进行叠加重构, 得到最终的预测结果;
- 7) 对不同模型得到的预测结果进行误差分析与对比。

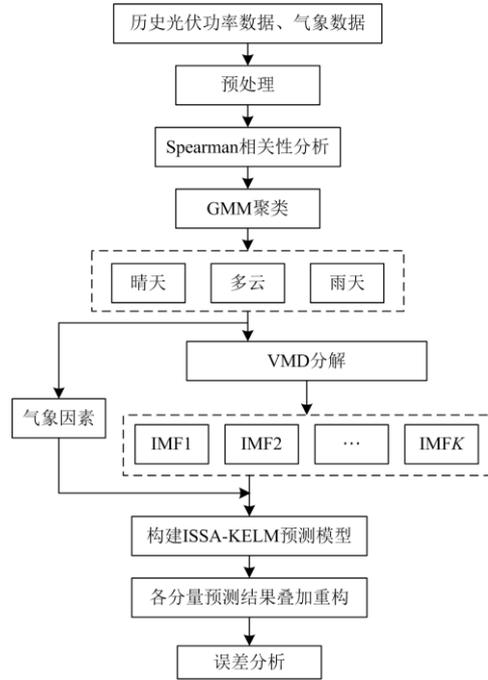


图 2 基于 VMD-ISSA-KELM 短期光伏发电功率预测流程

Fig. 2 Flow chart of short-term photovoltaic power generation prediction based on VMD-ISSA-KELM

## 4 实例分析

### 4.1 评价指标

本文选用均方根误差 (root mean square error, RMSE)  $X_{RMSE}$ 、平均绝对误差 (mean absolute error, MAE)  $X_{MAE}$ 、平均绝对百分比误差 (mean absolute percentage error, MAPE)  $X_{MAPE}$  作为评价指标, 更好地评估不同模型的预测性能, 具体表达式为

$$X_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{p}_i - p_i)^2} \quad (26)$$

$$X_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{p}_i - p_i| \quad (27)$$

$$X_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{p}_i - p_i|}{p_i} \times 100\% \quad (28)$$

式中:  $p_i$  为实际光伏发电功率;  $\hat{p}_i$  为预测光伏发电功率。

### 4.2 数据描述及预处理分析

以澳大利亚太阳能研发中心某光伏电站实测数据为例<sup>[32]</sup>，将 2016 年第 2 季度前 60 天的发电功率及气象数据作为原始样本。由于光伏发电系统通常只在白天出力，因此选取 06:30—18:30 时间段内的数据，采样间隔为 5 min，每天总计 145 个样本点。

利用高斯聚类模型对原始光伏发电功率样本进行相似日选取，得到 3 种不同天气类型的相似日样本，其中晴天 22 天，多云 20 天，雨天 18 天。在不同天气类型相似日样本中随机选择 4 天作为测试样本，其余作为训练样本。

利用 VMD 对不同天气类型的相似日样本进行平稳化处理，得到若干规律性较强的子序列。为了得到更加可靠的数据集，充分挖掘光伏发电功率序列内在的规律，选择合适的模态分解数  $k$  十分关键。经过多次仿真实验，对于不同天气类型的光伏发电序列，当  $k=6$  时 VMD 分解得到的子序列没有明显的模态混叠现象，且以此建立的数据集训练模型具有更好的预测效果，同时为了保证原始序列分解的保真度，本文将惩罚参数、初始的中心频率和收敛准则容忍度分别设定为  $\alpha=2000$ 、 $\omega_0=1$  和  $\tau=1 \times 10^{-7}$ 。以雨天的光伏发电功率序列为例，经 VMD 分解得到的子序列如图 3 所示。

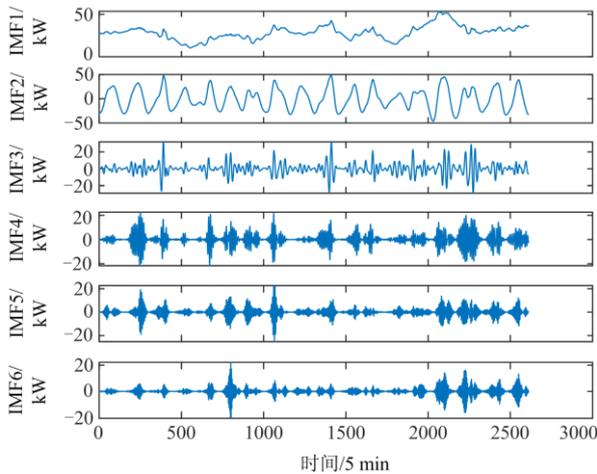


图 3 雨天天气类型下光伏发电功率序列的 VMD 分解结果

Fig. 3 VMD decomposition results of photovoltaic power generation sequence under rainy day

由图 3 可知，利用 VMD 对雨天的光伏发电序列进行分解，得到 6 个规律性较强的分量。IMF1 为主导分量，具有频率低，曲线平滑的特点，其可以表征光伏发电功率的整体趋势，而其余各分量虽然频率各异，但整体表现为一定的规律性，能反映光伏功率序列局部的特征。

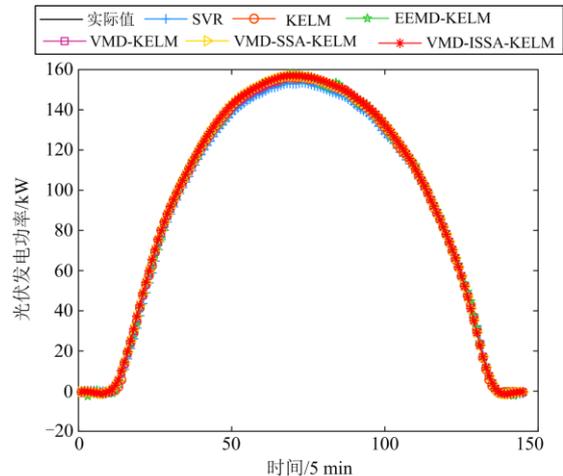
### 4.3 预测结果分析

为了验证所提预测模型的有效性和优越性，选取多种典型预测模型与其比较，包括 SVR、KELM、VMD-LSTM、EEMD-LSTM、VMD-SSA-KELM，模型参数设置如下，对于 SVR 模型，两个参数惩罚因子  $\gamma$  和核参数  $\eta$  采用网格搜索及交叉验证法所得，搜索范围为  $[2^{-10}, 2^{10}]$ ；对于未优化的 KELM 模型，核参数  $g=1000$ ，正则化系数  $C=100$ ；对于 SSA 和 ISSA 算法，滑行常数  $G_c=1.9$ ，捕食者概率  $P_{dp}=0.1$ ，种群规模  $N=50$ ，最大迭代次数  $T_{max}=100$ ，维度  $D=2$ ，核参数  $g$  和正则化系数  $C$  的搜索范围为  $[10^{-2}, 10^5]$ 。

为了提高结果的可靠性，对于不同模型的输入量均保持一致，共计 7 个输入特征，即对应时刻的 4 个气象因素及前 15 min 的历史光伏发电功率值，输出量为对应时刻光伏发电功率值。为了避免不同输入特征的数量级对预测的影响，训练模型前先将样本数据集统一归一化至  $[0,1]$ 。对晴天、多云、雨天 3 种不同天气类型的光伏发电功率进行预测，得到不同模型的预测结果，分别计算不同模型的  $X_{RMSE}$ 、 $X_{MAE}$  和  $X_{MAPE}$ ，并对预测结果对比分析。图 4 为不同天气类型光伏发电功率在不同预测模型下的预测结果。

由图 4(a)可以看出，晴天的光伏发电功率曲线频率波动较为稳定，且不同预测模型得到的功率拟合曲线均十分接近实际曲线，由此表明，不同预测模型对晴天天气类型下的光伏发电功率具有较好的适应性，能够对光伏发电功率做出较为准确的预测。

由图 4(b)可以看出，不同模型得到的功率拟合曲线与实际曲线具有较大偏差，这是由于多云天气类型下的光伏发电功率由于受云朵和光照辐射量的影响，曲线整体呈现较强的波动性和随机性，因此



(a) 晴天(2016年5月17日)

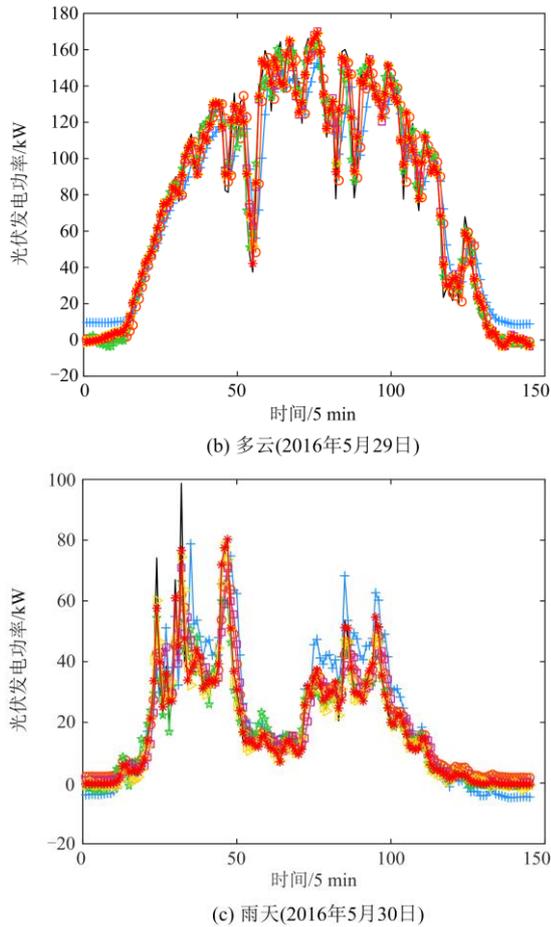


图 4 不同天气类型预测结果

Fig. 4 Prediction results for different weather types

对不同模型的适应性也不同,传统的 SVR 和 KELM 预测模型得到的功率拟合曲线与实际曲线偏差略大,利用 EEMD、VMD 分解方法与 KELM 组合预测模型得到功率拟合曲线要优于传统模型。

由图 4(c)可以看出,雨天的光伏发电功率曲线频率波动较大,随机性也较为强烈,整体幅值均要小于晴天及多云天气类型,不同预测模型得到的功率拟合曲线与实际曲线偏差较大,但相比而言,经优化的 VMD-KELM 模型得到的功率拟合曲线更为接近实际曲线,由此说明,经优化的 VMD-KELM 模型具有更强的预测性能。

表 2 为不同天气类型在不同预测模型的预测误差对比。表中给出了晴天、多云和雨天 3 种不同天气在 6 种预测模型下的均方根误差  $X_{RMSE}$ 、平均绝对误差  $X_{MAE}$ 、平均绝对百分比误差  $X_{MAPE}$  的对比结果。由表 2 可知,对于 3 种不同天气类型,晴天天气类型的光伏发电预测精度要明显优于多云及雨天天气类型,这是由于多云和雨天的光伏发电功率具有明显的随机性和波动性,而晴天的光伏发电功率

较为稳定,因此预测模型对晴天的光伏发电功率适应性要强于另外两种天气类型。

表 2 不同天气类型下各模型的预测误差对比

Table 2 Comparison of predictive errors of each model under different weather types

| 天气 | 预测模型          | $X_{RMSE}/kW$ | $X_{MAE}/kW$ | $X_{MAPE}/\%$ |
|----|---------------|---------------|--------------|---------------|
| 晴天 | SVR           | 5.0412        | 4.5239       | 3.1969        |
|    | KELM          | 1.3191        | 1.0439       | 0.7795        |
|    | EEMD-KELM     | 1.0830        | 0.6513       | 0.5152        |
|    | VMD-KELM      | 0.9298        | 0.7162       | 0.4991        |
|    | VMD-SSA-KELM  | 0.7276        | 0.5105       | 0.3335        |
|    | VMD-ISSA-KELM | 0.7146        | 0.4961       | 0.3225        |
| 多云 | SVR           | 16.7381       | 13.6580      | 11.5938       |
|    | KELM          | 12.9949       | 7.9222       | 7.1935        |
|    | EEMD-KELM     | 9.3969        | 6.4278       | 5.2310        |
|    | VMD-KELM      | 7.8130        | 5.5355       | 4.9342        |
|    | VMD-SSA-KELM  | 7.3152        | 5.1482       | 4.6758        |
|    | VMD-ISSA-KELM | 7.2442        | 5.0812       | 4.6162        |
| 雨天 | SVR           | 11.9219       | 7.5767       | 27.5798       |
|    | KELM          | 8.6239        | 6.1453       | 18.9261       |
|    | EEMD-KELM     | 6.4522        | 4.0871       | 16.1254       |
|    | VMD-KELM      | 5.8016        | 3.2385       | 15.7947       |
|    | VMD-SSA-KELM  | 5.5543        | 3.0494       | 14.9062       |
|    | VMD-ISSA-KELM | 5.5064        | 3.0275       | 14.6967       |

由表 2 可知,6 种预测模型均能较为准确地对 3 种不同天气类型下的光伏发电功率做出预测,但相比之下,组合预测模型得到的预测精度要优于单一的 SVR、KELM 模型。而对于 EEMD-KELM 和 VMD-KELM 两种组合预测模型来说,结果显示 VMD-KELM 得到的预测误差更小,由此表明基于 VMD 方法对光伏功率数据进行平稳化处理更具有优势,能够获得更高的预测精度。相比于 VMD-KELM 模型,VMD-SSA-KELM 模型在晴天、多云和雨天天气类型下的  $X_{RMSE}$  分别下降了 21.7466%、6.3714%、4.2626%,  $X_{MAE}$  分别下降了 28.7210%、6.9967%、5.8391%,  $X_{MAPE}$  分别下降了 31.1797%、5.2369%、5.6253%,由此表明,通过 VMD 平稳化处理,利用 SSA 优化的 KELM 具有更强的预测性能。而 VMD-ISSA-KELM 模型相较于 VMD-SSA-KELM 具有更强的适应性,在晴天、多云和雨天天气类型下的  $X_{RMSE}$  分别下降了 1.7867%、0.9706%、0.8624%,  $X_{MAE}$  分别下降了 2.8208%、1.3014%、0.7182%,  $X_{MAPE}$  分别下降了 3.2984%、1.2746%、1.4055%,也由此表明,ISSA 相较于 SSA 具有更强的稳定性和寻优能力,能够更为有效地提高 KELM 的预测性能,也表明本文所提模型的有效性和优越性。

为了进一步验证所提模型的优势,将3种不同天气类型下的光伏预测误差结果取平均值,并与其他文献提出的模型作对比,结果如表3所示。从表3中可知,在 $X_{MAPE}$ 评价指标下,本文提出的模型 $X_{MAPE}$ 为6.5451%,明显优于其他对比模型,进一步验证了本文所提模型具有更强的预测性能。

表3 与其他组合模型的误差比较结果

| 预测模型                             | $X_{MAPE}/\%$ |
|----------------------------------|---------------|
| EEMD-MPE-LSSVM <sup>[33]</sup>   | 7.2060        |
| CEEMDAN-IBA-KELM <sup>[34]</sup> | 6.6272        |
| VMD-EGWO-ELM <sup>[35]</sup>     | 7.0082        |
| VMD-GWO-ELMAN <sup>[36]</sup>    | 6.8156        |
| VMD-ISSA-KELM                    | 6.5451        |

## 5 结论

为了提高短期光伏发电功率的预测精度,本文提出了一种VMD-ISSA-KELM的预测模型,结合具体算例,得到结论如下:

1) 针对随机性、波动性较强的光伏发电功率序列,利用VMD方法对其进行平稳化处理,得到若干个规律性较强的子序列,不仅能够避免模态混叠现象,而且能减小在分解预测重构时的误差,具有更好的适应性和分解效果。

2) 针对KELM模型因参数选择不当而导致预测性能低下的问题,提出了ISSA用于优化KELM参数,结果表明,ISSA可以为KELM寻得更优参数解,且能有效提高其预测性能。

3) 仿真结果表明,VMD-ISSA-KELM模型能够有效对短期光伏发电功率做出预测,且在不同天气类型下得到的3个评价指标均优于其他模型,具有良好的适应性和预测性能,应用前景良好。

## 参考文献

- [1] 鲍长庚, 闫贻鹏, 黄一楠, 等. 基于多元自适应回归样条的光伏并网系统日输出功率预测[J]. 电力系统保护与控制, 2021, 49(5): 124-131.  
BAO Changeng, YAN Yipeng, HUANG Yinan, et al. Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines[J]. Power System Protection and Control, 2021, 49(5): 124-131.
- [2] WANG K, QI X, LIU H. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. Applied Energy, 2019, 251.
- [3] 崔佳豪, 毕利. 基于混合神经网络的光伏电量预测模型的研究[J]. 电力系统保护与控制, 2021, 49(13): 142-149.
- [4] CUI Jiahao, BI Li. Research on photovoltaic power forecasting model based on hybrid neural network[J]. Power System Protection and Control, 2021, 49(13): 142-149.
- [5] 王晗, 严正, 徐潇源, 等. 基于稀疏多项式混沌展开的孤岛微电网全局灵敏度分析[J]. 电力系统自动化, 2019, 43(10): 44-57.  
WANG Han, YAN Zheng, XU Xiaoyuan, et al. Global sensitivity analysis for islanded microgrid based on sparse polynomial chaos expansion[J]. Automation of Electric Power Systems, 2019, 43(10): 44-57.
- [5] 刘倩, 胡强, 杨凌帆, 等. 基于时间序列的深度学习光伏发电模型研究[J]. 电力系统保护与控制, 2021, 49(19): 87-98.
- [5] LIU Qian, HU Qiang, YANG Lingfan, et al. Deep learning photovoltaic power generation model based on time series[J]. Power System Protection and Control, 2021, 49(19): 87-98.
- [6] 吉梓格, 李慧, 刘思嘉, 等. 基于MIE-LSTM的短期光伏功率预测[J]. 电力系统保护与控制, 2020, 48(7): 50-57.
- [6] JI Xingge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. Power System Protection and Control, 2020, 48(7): 50-57.
- [7] BOZORG M, BRACALE A, CARAMIA P, et al. Bayesian bootstrap quantile regression for probabilistic photovoltaic power forecasting[J]. Protection and Control of Modern Power Systems, 2020, 5(2): 1-12.
- [8] 安鹏跃, 孙堃. 基于相似日和回声状态网络的光伏发电功率预测[J]. 智慧电力, 2020, 48(8): 38-43.  
AN Pengyue, SUN Kun. Photovoltaic power prediction based on similar day and echo state networks[J]. Smart Power, 2020, 48(8): 38-43.
- [9] 赖昌伟, 黎静华, 陈博, 等. 光伏发电出力预测技术研究综述[J]. 电工技术学报, 2019, 34(6): 1201-1217.  
LAI Changwei, LI Jinghua, CHEN Bo, et al. Review of photovoltaic power output prediction technology[J]. Transactions of China Electrotechnical Society, 2019, 34(6): 1201-1217.
- [10] 龚莺飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(4): 140-151.  
GONG Yingfei, LU Zongxiang, QIAO Ying, et al. An overview of photovoltaic energy system output forecasting technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140-151.
- [11] 叶林, 裴铭, 路朋, 等. 基于天气分型的短期光伏功率组合预测方法[J]. 电力系统自动化, 2021, 45(1): 44-54.

- YE Lin, PEI Ming, LU Peng, et al. Combination forecasting method of short-term photovoltaic power based on weather classification[J]. *Automation of Electric Power Systems*, 2021, 45(1): 44-54.
- [12] 张金金, 张倩, 马愿, 等. 模糊聚类-Elman 神经网络短期光伏发电预测模型[J]. *电测与仪表*, 2020, 57(12): 46-51.
- ZHANG Jinjin, ZHANG Qian, MA Yuan, et al. Fuzzy clustering-Elman neural network model for short-term photovoltaic power generation prediction[J]. *Electrical Measurement & Instrumentation*, 2020, 57(12): 46-51.
- [13] 王昕, 黄柯, 郑益慧, 等. 基于萤火虫算法-广义回归神经网络的光伏发电功率组合预测[J]. *电网技术*, 2017, 41(2): 455-461.
- WANG Xin, HUANG Ke, ZHENG Yihui, et al. Combined PV power forecast based on firefly algorithm-generalized regression neural network[J]. *Power System Technology*, 2017, 41(2): 455-461.
- [14] ZHANG Yang, LI Ce, LI Lian. Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods[J]. *Applied Energy*, 2017, 190: 291-305.
- [15] 章勇高, 高彦丽, 马迪. 基于 GA-KELM 的光伏短期出力预测研究[J]. *控制工程*, 2018, 25(7): 1155-1159.
- ZHANG Yonggao, GAO Yanli, MA Di. Research of photo-voltaic short-term output power prediction based on GA-KELM[J]. *Control Engineering of China*, 2018, 25(7): 1155-1159.
- [16] 赵鹏, 涂菁菁, 杨锡运. 基于 PSO-KELM 的风功率预测研究[J]. *电测与仪表*, 2020, 57(11): 24-29.
- ZHAO Peng, TU Jingjing, YANG Xiyun. Research of wind power prediction based on PSO-KELM[J]. *Electrical Measurement & Instrumentation*, 2020, 57(11): 24-29.
- [17] WU X, LAI C S, BAI C, et al. Optimal kernel ELM and variational mode decomposition for probabilistic PV power prediction[J]. *Energies*, 2020, 13(14): 1-21.
- [18] JAIN M, SINGH V, RANI A. A novel nature-inspired algorithm for optimization: squirrel search algorithm[J]. *Swarm and Evolutionary Computation*, 2019, 44(2): 148-175.
- [19] 王育飞, 付玉超, 薛花. 基于 Chaos-EEMD-PFBD 分解和 GA-BP 神经网络的光伏发电功率超短期预测法[J]. *太阳能学报*, 2020, 41(12): 55-62.
- WANG Yufei, FU Yuchao, XUE Hua. Ultra-short-term forecasting method of photovoltaic power generation based on Chaos-EEMD-PFBD decomposition and GA-BP neural networks[J]. *Acta Energetica Solaris Sinica*, 2020, 41(12): 55-62.
- [20] ZHANG N, REN Q, LIU G, et al. Short-term PV output power forecasting based on CEEMDAN-AE-GRU[J]. *Journal of Electrical Engineering & Technology*, 2022, 17(2): 1183-1194.
- [21] 朱玥, 顾洁, 孟璐. 基于 EMD-LSTM 的光伏发电预测模型[J]. *电力工程技术*, 2020, 39(2): 51-58.
- ZHU Yue, GU Jie, MENG Lu. Photovoltaic power generation prediction model based on EMD-LSTM[J]. *Electric Power Engineering Technology*, 2020, 39(2): 51-58.
- [22] 孙建波. 基于 EEMD 与变权组合预测的光伏发电预测模型及应用研究[D]. 北京: 华北电力大学, 2019.
- SUN Jianbo. Photovoltaic generation prediction model based on EEMD variable weight combination forecasting and application research[D]. Beijing: North China Electric Power University, 2019.
- [23] 杨晶显, 张帅, 刘继春, 等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测[J]. *电力系统自动化*, 2021, 45(3): 174-182.
- YANG Jingxian, ZHANG Shuai, LIU Jichun, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long short-term memory with dual-stage attention mechanism[J]. *Automation of Electric Power Systems*, 2021, 45(3): 174-182.
- [24] 高相铭, 杨世凤, 潘三博. 基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测研究[J]. *电力系统保护与控制*, 2015, 43(21): 86-92.
- GAO Xiangming, YANG Shifeng, PAN Sanbo. A forecasting model for output power of grid-connected photovoltaic generation system based on EMD and ABC-SVM[J]. *Power System Protection and Control*, 2015, 43(21): 86-92.
- [25] 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.
- [26] IRANI M, DASH P, RANJEETA B. Variational mode decomposition based low rank robust kernel extreme learning machine for solar irradiation forecasting[J]. *Energy Conversion and Management*, 2018, 171: 787-806.
- [27] 张美霞, 李丽, 杨秀, 等. 基于高斯混合模型聚类和多维尺度分析的负荷分类方法[J]. *电网技术*, 2020, 44(11): 4283-4296.
- ZHANG Meixia, LI Li, YANG Xiu, et al. A load classification method based on Gaussian mixture model

- clustering and multi-dimensional scaling analysis[J]. Power System Technology, 2020, 44(11): 4283-4296.
- [28] LI K, MA Z, ROBINSON D, et al. Identification of typical building daily electricity usage profiles using Gaussian mixture model-based clustering and hierarchical clustering[J]. Applied Energy, 2018, 231: 331-342.
- [29] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C] // International Conference on International Conference on Computational Intelligence for Modelling, Control & Automation, November 28-30, 2005, Vienna, Austria: 695-701.
- [30] 刘兴阳, 毛力. 基于  $t$  分布变异的自适应差分进化算法[J]. 计算机工程与应用, 2012, 48(2): 127-129.  
LIU Xingyang, MAO Li. Self-adaptive differential evolution algorithm using mutations based on the  $t$  distribution[J]. Computer Engineering and Applications, 2012, 48(2): 127-129.
- [31] 何庆, 林杰, 徐航. 混合柯西变异和均匀分布的蝗虫优化算法[J]. 控制与决策, 2021, 36(7): 1558-1568.  
HE Qing, LIN Jie, XU Hang. Hybrid Cauchy mutation and uniform distribution of grasshopper optimization algorithm[J]. Control and Decision, 2021, 36(7): 1558-1568.
- [32] Desert Knowledge Australia Centre. Location (Yulara Solar System) [EB/OL]. [2021-07-25]. <http://dkasolarcentre.com.au/download>.
- [33] 朱瑞金, 龚雪娇, 张娟娟. 基于 EEMD-MPE-LSSVM 的光伏发电功率预测[J]. 中国测试, 2021, 47(9): 158-162.  
ZHU Ruijin, GONG Xuejiao, ZHANG Juanjuan. Forecast of photovoltaic power generation based on EEMD-MPE-LSSVM[J]. China Measurement & Test, 2021, 47(9): 158-162.
- [34] 田德, 张琦. 基于优化核极限学习机的光伏出力短期预测[J]. 电力科学与工程, 2017, 33(12): 15-21.  
TIAN De, ZHANG Qi. Short term prediction of photovoltaic output based on optimized kernel extreme learning machine[J]. Electric Power Science and Engineering, 2017, 33(12): 15-21.
- [35] LIU Z, LUO S, TSENG M, et al. Short-term photovoltaic power prediction on modal reconstruction: a novel hybrid model approach[J]. Sustainable Energy Technologies and Assessments, 2021, 45.
- [36] 张娜, 任强, 刘广忱, 等. 基于 VMD-GWO-ELMAN 的短期光伏功率预测[J/OL]. 中国电力: 1-9[2022-01-30]. <http://kns.cnki.net/kcms/detail/11.3265.TM.20210827.1455.004.html>  
ZHANG Na, REN Qiang, LIU Guangchen, et al. PV power short-term forecasting method based on VMD-GWO-ELMAN[J/OL]. Electric Power: 1-9[2022-01-30]. <http://kns.cnki.net/kcms/detail/11.3265.TM.20210827.1455.004.html>.

收稿日期: 2022-02-02; 修回日期: 2022-04-27

作者简介:

商立群(1968—), 男, 通信作者, 博士, 教授, 研究方向为电力系统分析与控制、新能源发电等; E-mail: shanglq@xust.edu.cn

李洪波(1997—), 男, 硕士研究生, 研究方向为新能源功率预测; E-mail: lihb024295@163.com

侯亚东(1996—), 男, 硕士研究生, 研究方向为电力设备故障诊断。E-mail: houyd55244@163.com

(编辑 周金梅)