

DOI:10.19651/j.cnki.emt.2211575

# 基于特征因素选取的 IVMD-GLSSVM 光伏出力短期预测<sup>\*</sup>

袁建华 李洪强 谢斌斌 何宝林 蒋文军 徐杰  
(三峡大学电气与新能源学院 宜昌 443000)

**摘要:** 针对短期光伏发电功率预测输入特征数据冗余,抗干扰能力差,预测精度受限等问题,提出了基于特征因素选取的 IVMD-GLSSVM 短期光伏出力预测模型。首先利用 GRA-KCC 对影响特征因素进行分析,提取影响光伏发电功率的极相关特征因素,随后采用 IVMD 对光伏发电数据进行分解,降低数据非线性和波动性对预测精度的影响。然后将各模态分量分别输入 GLSSVM 预测模型进行预测,求得的各子序列预测结果叠加即为最终预测结果。最后在 MATLAB 中对该预测模型及其他模型进行算例验证和误差分析,结果表明采用所提预测模型抗干扰能力强,预测精度高。

**关键词:** 光伏功率预测;特征提取;改进变分模态分解;灰狼优化;最小二乘支持向量机

**中图分类号:** TP271 **文献标识码:** A **国家标准学科分类代码:** 470.4047

## Short term forecasting of photovoltaic output based on feature factor selection and IVMD-GLSSVM

Yuan Jianhua Li Hongqiang Xie Binbin He Baolin Jiang Wenjun Xu Jie  
(College of Electrical Engineering & New Energy, Three Gorges University, Yichang 443000, China)

**Abstract:** Aiming at the problems of redundant input characteristic data, poor anti-interference ability and limited predictive accuracy in short-term photovoltaic power prediction, short term forecasting of photovoltaic output based on feature factor selection and IVMD-GLSSVM is proposed. Firstly, GRA-KCC is used to analyze the characteristic factors that affect the photovoltaic power, and extract the extremely relevant characteristic factors that affect the photovoltaic power. Then IVMD is used to decompose the photovoltaic power data to reduce the impact of data nonlinearity and volatility on prediction accuracy. Then each modal component is input into the GLSSVM prediction model for prediction, and the superposition of the prediction results of each subsequence is the final prediction result. Finally, the prediction model and other models are verified and analyzed in MATLAB. The results show that the proposed prediction model has strong anti-interference ability and high prediction accuracy.

**Keywords:** photovoltaic power prediction; feature extraction; improved variational modal decomposition; grey wolf optimization; least squares support vector machine

## 0 引言

随着“双碳”目标的推进,光伏发电作为绿色可再生能源发展前景广阔。但是由于光伏发电受到太阳光照强度、相对湿度、环境温度等外界因素的影响,所以其具有较强的随机性和波动性。随着光伏发电在电力系统的渗透率增加,光伏出力不稳定的特点给电网的安全运行带来的潜在隐患也不断增加<sup>[1-2]</sup>。因此准确预测光伏发电功率对电力

部门调度、检修和制定发电计划等有很大帮助<sup>[3]</sup>。

针对上述问题,国内外学者提出了多种预测方法应对光伏发电功率的随机性,提高预测精度。主要分为间接预测法和直接预测法。间接预测法主要是根据光伏电站详细的地理位置信息、历史功率曲线以及逆变器系统等技术参数对光伏发电每个过程分别建模,然后利用未来气象信息进行功率预测。直接预测法是根据历史气象数据和同期光伏系统发电功率数据来建立预测模型,常用方法包括神经

收稿日期:2022-09-30

<sup>\*</sup> 基金项目:煤燃烧国家重点实验室开放基金(FSKLCCA1607)、梯级水电站运行与控制湖北省重点实验室基金(2015KJX07)项目资助

网络算法、支持向量机、马尔科夫链预测及回声状态网络等<sup>[4-6]</sup>。间接预测法计算公式本身存在一定误差,且模型抗干扰能力不强,鲁棒性较差,因此目前多使用直接预测法。文献[9]采用变分模态分解(variational mode decomposition, VMD)对 K-means 算法按天气类型聚类的数据进行分解,将分解子序列输入灰狼算法(grey wolf optimizer, GWO)优化的 ELMAN 神经网络模型进行预测。该方法预测效果较好,但 VMD 采用经验值,存在过分解或欠分解的弊端;文献[10]采用粒子群算法对长短期记忆网络参数进行优化处理,然后利用优化的长短期记忆网络分别对不同季节的光伏出力进行预测,结果表明优化参数的网络预测精度和泛化能力有一定提高。文献[11]分析了光伏发电功率的影响因素,提取了太阳辐射度、环境湿度和环境温度 3 个因素作为预测模型的输入,但是未考虑因素之间的相关性,存在数据冗余,限制了预测精度。文献[12]中朱瑞金等采用多尺度排列熵(multiscale permutation entropy, MPE)量化不同天气类型的最小二乘支持向量机(least squares support vector machine, LSSVM)预测方法,该方法验证了 LSSVM 的小样本预测的优势,但未对 LSSVM 参数进行优化处理,抑制了 LSSVM 泛化能力。

针对上述输入预测模型数据存在冗余、VMD 分解不够准确及 LSSVM 泛化能力差等问题,本文提出基于灰色关联分析(grey relation analysis, GRA)-肯德尔相关系数(Kendall correlation coefficient, KCC)提取特征因素的改进 VMD(improved variational mode decomposition, IVMD)-灰狼优化 LSSVM(grey wolf optimize least squares support vector machine, GLSSVM)的光伏发电功率预测模型。首先聚集灰色关联与肯德尔相关系数优势互补,剔除不相关和冗余因素,将输出功率以及提取的特征数据输入 IVMD 进行模态分解,然后将分解子序列输入 GLSSVM 预测模型,最后将各模态预测结果进行叠加。通过对不同天气类型进行仿真,并与其他方法模型进行对比,验证了本文所提模型的有效性。

## 1 GRA-KCC 光伏功率预测特征提取

### 1.1 GRA 理论

GRA 是通过对比因变量和多个自变量的几何形状相似度,确定各自变量与因变量之间关联程度。通常采用该方法计算关联度值衡量各因素对于结果的贡献度,计算具体步骤如文献[13]。关联度计算公式如式(1):

$$\gamma_{oi} = \frac{1}{n} \sum_{k=1}^n \frac{m + \xi M}{\Delta_i(k) + \xi M}, \quad k = 1, 2, \dots, n; i = 1, 2, \dots, p \quad (1)$$

式中:  $\Delta_i(k)$  表示因变量与各自变量之间绝对差值,  $\xi$  表示分辨系数,一般取值 0.5,  $M = \max \Delta_i(k)$ ,  $m = \min \Delta_i(k)$ 。

### 1.2 KCC 理论

KCC 利用两参量之间协同一致和非协同一致的概

率之差表示其相关性,该系数可衡量非线性参量之间相关程度。KCC 详细计算参考文献[14],相关系数计算公式如式(2):

$$\tau_n = \frac{P - Q}{\sqrt{(P + Q + T_x)(P + Q + T_y)}} \quad (2)$$

式中:  $P$  表示和谐对的个数,  $Q$  表示不和谐对的个数,  $N$  表示样本个数,  $T_{x(y)}$  表示在  $x(y)$  上相持。

### 1.3 基于 GRA-KCC 特征因素提取

通过光伏电站监测数据包括多个影响光伏发电功率特征因素,但丰富的多特征信息会含有多种冗余信息,给预测工作增加大量的计算负担,并且降低预测精度。因此,采用 GRA-KCC 对特征因素进行提取。

取某光伏电站所监测数据,利用 GRA 计算各个特征因素对光伏发电功率的影响程度,所得结果如图 1 所示。




图 1 GRA 相关度

通过图 1 可以看出,气压和相对湿度对发电功率的影响程度较小,因此将其剔除。但是 GRA 只考虑了各特征对光伏发电功率的相关度,忽略了特征之间的耦合性,所以只靠一种方法难以将冗余信息剔除,需要计算另一种表征特征之间耦合度的相关系数对特征参量进一步选择。

每组特征参数均连续,且两组特征参量之间相互独立,考虑到参量间呈非线性关系,故本文选用 KCC 对参量之间相关性进行研究。采用 KCC 进行计算,得到各特征参量之间相关性热力图如图 2 所示。

图中,椭圆左斜表示正相关,椭圆右斜表示负相关。通过图 2 可以看出组件温度和太阳辐射之间相关性较强,环境温度与太阳辐射之间相关性较弱,故组件温度与太阳辐射之间存在数据冗余,故将组件温度剔除。

综上所述,本文选取太阳辐射和环境温度作为预测模型输入,对光伏发电功率预测问题进行研究。

## 2 IVMD-GLSSVM 的光伏发电功率预测算法

### 2.1 IVMD 算法理论分析

VMD 是一种可以有效分解非平稳信号,处理信号噪




图2 相关性热力图

声干扰和模态混叠问题的信号分解方法<sup>[15]</sup>。将功率原始时间序列  $f(t)$  通过迭代搜寻变分模型分解为中心频率为  $\omega_k$  的  $K$  个模态分量  $u_k$ , 提高模型的抗干扰能力。

在 VMD 的计算步骤中, 学者引入了二次惩罚因子  $\alpha$  和拉格朗日乘子  $\lambda$  将约束极值问题转化为无约束问题进行求解<sup>[16]</sup>, 如式(3)所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \|\partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t}\|_2^2 + \|f(t) - \sum_{k=1}^K u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (3)$$

式中:  $u_k$ 、 $\omega_k$  分别表示分解后第  $k$  个模态分量和该分量对应的中心频率,  $\partial_t$  表示求偏导数,  $K$  表示模态分量总数,  $\alpha$  表示二次惩罚因子和  $\lambda$  表示拉格朗日乘子。

由式(3)可知, 分解模态个数  $K$  和惩罚因子  $\alpha$  直接影响 VMD 分解结果准确度<sup>[17-18]</sup>, 参数  $K$  和  $\alpha$  取值不合理会导致数据欠分解或过分解, 故本文采用遗传算法 (genetic algorithm, GA) 对 VMD 参数寻优处理, 组成 IVMD, 克服了传统 VMD 数据分解的弊端。

GA 是一种基于自然选择和遗传学机理的搜寻最优解的方法, 该算法具有全局搜寻能力强、寻优速度快等优点。遗传算法具体过程及思想如文献[19-20]所示。本文将样本熵 (sample entropy, SE)<sup>[21]</sup> 作为 GA 的适应度函数对 VMD 参数优化, SE 公式如式(4)所示, 优化步骤框图如图3所示。

$$\text{SampleEn}(s, r, q) = -\ln \frac{B(r)^{s+1}}{B(r)^s} \quad (4)$$

式中:  $r$  表示相似容限阈值,  $s$  表示重构相空间矩阵维度,  $B(r)^s$  和  $B(r)^{s+1}$  分别表示两序列在相似容限  $r$  时匹配  $s$  个点和  $s+1$  个点的概率,  $q$  表示数据组的个数。

## 2.2 IVMD 功率及特征因素时间序列分解

选7天中7:00~19:00时段光伏发电功率, 变化曲线如图4所示, 从图中可以看出输出功率具有非线性和波动性, 故用 IVMD 对光伏输出功率及影响因素进行分解后再预测, 增加模型的抗干扰能力。

采用 GA 对 VMD 参数优化得到最优  $K$ 、 $\alpha$  组合。GA

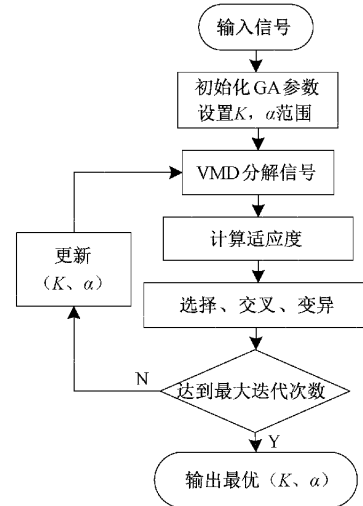


图3 GA优化VMD参数




图4 输出功率曲线

参数初始化: 令最大迭代次数为 20, 种群规模  $sizepop = 10$ , 交叉概率  $p_c = 0.8$ , 变异概率  $p_m = 0.1$ ,  $\alpha \in [500, 3000]$ ,  $K \in [3, 10]$ 。最终寻优结果为  $(K, \alpha) = (8, 1906)$ 。取某天功率数据比较所提 IVMD、传统 VMD 及采用中心频率法<sup>[22]</sup>获取参数的 VMD 分解后重组数据与原数据的平均绝对偏差, 偏差曲线如图5所示。




图5 平均绝对偏差

由图 5 可知,与选取经验值的传统 VMD 及由中心频率获取参数的 VMD 相比,所提 IVMD 分解后重组数据与原数据相差更小,分解更准确,验证了 IVMD 分解精度高的优势。

采用 IVMD 对太阳辐射、环境温度及发电功率数据分解结果分别如图 6~8 所示。




图 6 IVMD 太阳辐射分解




图 7 IVMD 环境温度分解

### 2.3 灰狼优化最小二乘支持向量机光伏功率预测模型

最小二乘支持向量机预测模型具有计算复杂度低、求解速度快等优点<sup>[23]</sup>,LSSVM 算法具体计算过程参考文献[24]。该算法处理数据过程中,根据 Mercer 条件,选用高斯函数作为核函数,对应式(5),最终拟合函数表达式如式(6)。可知,超参数惩罚因子  $\lambda$  和核函数带宽  $\sigma$  的选取直接影响其预测精度,因此本文使用全局寻优能力强,收敛速度快的灰狼算法对 LSSVM 的超参数进行优化,组成 GLSSVM 预测模型,对光伏发电功率进行预测。




图 8 IVMD 发电功率分解

$$K(x_i, x_j) = \exp\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (5)$$

$$f(x) = \sum_{i=1}^N \theta_i \exp\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) + b \quad (6)$$

式中: $K(x_i, x_j)$ 表示核函数, $x$ 表示输入样本数据, $\theta$ 表示惩罚因子, $\sigma$ 表示核函数带宽, $b$ 表示偏置误差。

灰狼算法是 2014 年由 Mirjalili 等根据模拟灰狼的社会等级和狩猎行为提出的一种新兴优化算法,该算法基于灰狼种群的协作机制达到优化的目的<sup>[25]</sup>。灰狼等级制度以及各狼职责由于篇幅原因详细请参考文献[26]。

灰狼算法对 LSSVM 的优化实质上是通过在 LSSVM 的初始惩罚因子  $\lambda$  和核函数带宽  $\sigma$  可解空间初始化一个灰狼群体,通过  $\alpha$  狼在可解空间不断更迭,以此获取位置和适应度最佳值,即为 LSSVM 最优参数。位置迭代公式为:

$$D = |C\Phi_{prey}(h) - \Phi(h)| \quad (7)$$

$$\Phi(h+1) = \Phi_{prey}(h) - AD \quad (8)$$

式中: $h$ 表示迭代次数, $\Phi_{prey}$ 、 $\Phi$ 分别表示猎物和灰狼的当前位置, $A$ 、 $C$ 表示系数向量,其表达式为:

$$A = 2ar_1 - a \quad (9)$$

$$C = 2r_2 \quad (10)$$

式中: $a$ 表示 2~0 随  $h$  递减的实数, $r_1, r_2 \in [0, 1]$ 。

本文所提 GLSSVM 算法预测流程如图 9 所示,基本步骤如下:

- 1) 导入 IVMD 分解的各模态分量数据,并对数据归一化处理;
- 2) 对 GWO 和 LSSVM 参数初始化,计算各狼的适应度,并根据适应度将狼群划分  $\alpha$ 、 $\beta$ 、 $\delta$ 、 $\omega$  这 4 个等级;
- 3) 根据 GWO 算法数学式(7)、(8)对灰狼个体位置进行更新,对新位置的灰狼重新计算适应度,并与位置变换前进行比较,若优于变换前,则对适应度替代,否则保留之前适应度;

4) 迭代循环至最大迭代次数停止, 输出  $\alpha$  狼位置和适应度, 即得到  $\theta$ 、 $\sigma$  最优解;

5) 根据灰狼算法得出的最优参数用训练集对 GLSSVM 模型进行训练, 得到最优 GLSSVM 模型;

6) 将预测集输入训练好的 GLSSVM 模型得到预测结果。

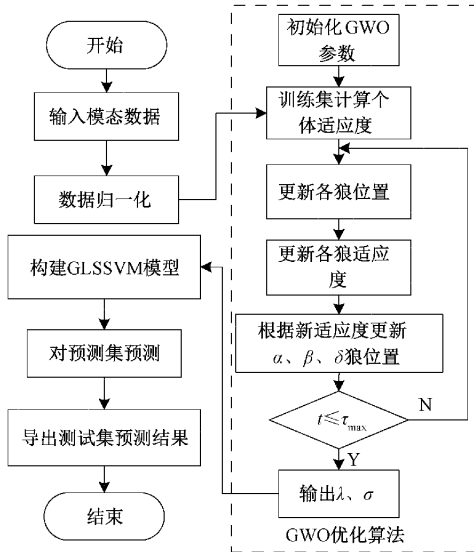


图9 GLSSVM 预测模型

### 3 基于特征提取的IVMD-GLSSVM的光伏出力预测

基于特征提取和IVMD-GLSSVM光伏出力预测过程如图10所示, 主要分为4个步骤。

1) 利用遗传算法优化确定VMD参数  $\alpha$ 、 $K$ , 将适应度最佳的一组数对输出作为VMD的参数;

2) 引入GRA-KCC剔除站点监测数据中的冗余和不相关因素, 然后利用IVMD方法分解历史功率和所筛选出的太阳辐射及环境温度等数据, 得到  $K$  个模态分量  $\{IMF_1, IMF_2, \dots, IMF_k\}$ ;

3) 对分解后的各分量输入GLSSVM预测模型, 得到各分量对应的预测值, 将各分量的预测结果进行叠加重构得到最终预测输出结果;

4) 计算误差指标分析该模型预测性能。选取均方根误差(RMSE)、平均绝对误差(MAE)和拟合优度( $R^2$ )作为评价各预测的标准, 其表达式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad (12)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

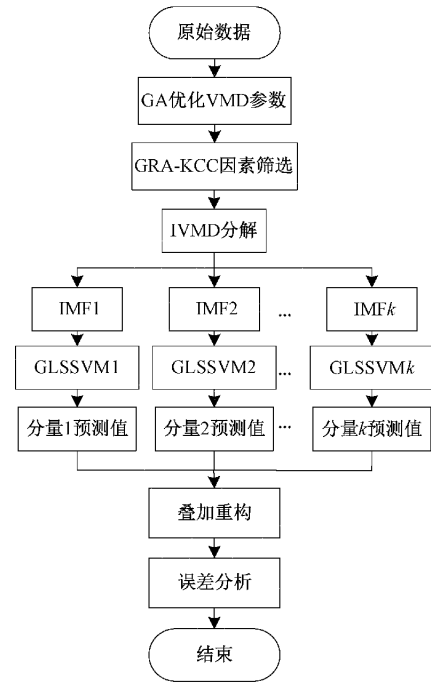


图10 基于特征提取和IVMD-GLSSVM的光伏出力预测过程

式中:  $y_i$ 、 $\hat{y}_i$  分别为第  $i$  个样本实际功率和模型预测功率,  $n$  表示测试样本数量。

### 4 算例分析

本文采用某光伏电站所监测数据, 记录仪每隔 15 min 采集一次, 由于夜间或凌晨光伏功率输出为 0 或很小, 所以取每天 7:00~19:00 时段的数据。任选一个月作为训练集, 选取 2 天为测试集。利用 MATLAB 软件建立所提预测模型, 对晴天、阴雨和多云 3 种不同类型天气进行预测分析验证。

根据 1.3 节 GRA-KCC 求解结果, 提取特征太阳辐射和环境温度作为输入, 发电功率作为输出。对两个特征因素数据进行模态分解, 然后将各模态分量输入 GLSSVM 预测模型得到各模态的预测值  $e_i$ , 最终预测值为  $\hat{y} = \sum e_i$ 。

为了验证本文所提方法中 GRA-KCC 特征提取、GWO 优化预测模型性能、以及 IVMD 降低数据波动性在提高模型预测精度和抗干扰能力等方面的优势以及检验所提方法应对不同天气类型时的有效性, 设计了 GLSSVM(方法 1)、GRA-KCC-LSSVM(方法 2) 及 GRA-KCC-GLSSVM(方法 3) 3 种方法, 并与本文所提的 GRA-KCC-IVMD-GLSSVM(方法 4) 分别在晴天、阴雨和多云 3 种不同天气状况下, 对 2 天光伏出力数据进行预测和分析比较。

首先初始化各模型参数, 设 GWO 算法种群数目  $N = 20$ , 最大迭代次数  $\tau_{\max} = 200$ , GA 参数如 2.2 节所述。晴天、多云和阴雨情况下各模型预测结果分别如图 11~13 所示。




图 11 晴天各模型预测结果曲线




图 12 多云各模型预测结果曲线




图 13 阴雨各模型预测结果曲线

根据式(11)~(13)计算模型在不同天气下各误差指标,  $RMSE$  和  $MAE$  值越小, 表明预测精度越高,  $R^2$  值越接近于 1, 预测结果越准确。晴天、多云和阴雨天气状况下的计算结果分别如表 1~3 所示。

由表 1 可知, 在晴天状况下, 由于功率变化比较平稳, 各模型预测精度都较高, 但 GLSSVM 和 GRA-KCC 特征提取的 GLSSVM 相比, 后者均方根误差、平均绝对误差分别降低了 25.14%、26.38%, 拟合优度提高了 1.623%, 体现

表 1 晴天各模型的预测误差

预测模型	$RMSE$	$MAE$	$R^2/\%$
方法 1	6.392 3	4.778 7	95.418
方法 2	5.300 3	3.787 6	96.316
方法 3	4.785 1	3.517 8	97.041
方法 4	3.922 2	3.043 2	97.749

表 2 多云各模型的预测误差

预测模型	$RMSE$	$MAE$	$R^2/\%$
方法 1	5.009	3.717 4	84.796
方法 2	4.999	3.271 8	85.475
方法 3	4.6265	2.874 4	87.32
方法 4	3.5387	2.368 3	93.002

表 3 阴雨各模型的预测误差

预测模型	$RMSE$	$MAE$	$R^2/\%$
方法 1	2.876 2	2.596 9	73.287
方法 2	1.252 5	0.845 2	80.849
方法 3	1.227 4	0.840 4	81.014
方法 4	0.696 1	0.507 4	94.676

出特征提取对提高预测精度的必要性。

由表 2、3 可知, 在多云和阴雨状态下, 天气易变导致发电功率波动大, 相较于特征提取但未采用 IVMD 方法的 GLSSVM 预测模型, 本文所提模型在多云和阴雨天气下均方根误差、平均绝对误差分别降低了 23.51% 和 43.28%、17.61% 和 39.62%, 拟合优度分别提高了 5.682% 和 13.662%, 各项指标提高明显, 体现了 IVMD 有效提高模型的抗干扰能力; 由于 LSSVM 参数随机赋值, 故在任何天气状态下, 具有特征提取的 GLSSVM 和具有特征提取的 LSSVM 模型相比, GLSSVM 各项指标都较优, 证实了采用 GWO 优化的必要性。

本文所提的 GRA-KCC 和 IVMD-GLSSVM 预测模型整合了 GRA-KCC 特征提取和 IVMD 两者的优势, 不仅剔除了冗余和不相关因素, 而且对原数据进行准确分解, 提高了预测模型的抗干扰能力和预测精度。晴天状态下, 所提模型均方根误差、平均绝对误差和拟合优度分别为 3.922 2、3.043 2 和 97.749%, 预测误差指标都优于其他模型。阴雨和多云天气状态下, 样本数据波动大, 所提模型具有特征提取优势和较强的抗干扰能力, 预测效果较其他模型效果更优。

通过算例仿真分析, 在晴天、阴雨和多云不同天气状况下, 本文所提模型各项指标都较其他模型有所提高, 验证了模型的有效性。

## 5 结 论

本文提出一种基于特征提取的 IVMD-GLSSVM 的光

光伏发电功率短期预测模型,以太阳辐射和环境温度作为模型输入量,发电功率作为输出量,结合某光伏电站所监测数据对不同天气状况发电量预测仿真分析,得出以下结论:

1)采用GRA-KCC提取太阳辐射和环境温度两个主要因素,剔除冗余和不相关因素(如组件温度、气压等)降低输入预测模型数据的维度,提高预测精度。

2)选用IVMD对数据样本进行准确分解,将分解后数据分别输入GLSSVM模型进行预测,最后将各模态预测结果进行叠加。避免数据波动带来的干扰,增加了模型抗干扰能力。

3)本文所提出的基于特征提取的IVMD-GLSSVM光伏发电功率短期预测模型结合了GRA-KCC特征提取和IVMD的优势,在不同天气类型下都表现出较好的预测效果。

### 参考文献

- [1] SHENG H M, XIAO J, CHENG Y H, et al. Short-term solar power forecasting based on weighted gaussian process regression[J]. IEEE Transactions on Industrial Electronics, 2018, 65(1):300-308.
- [2] 刘兴华, 耿晨, 谢胜寒, 等. 考虑光伏发电不确定性的日前火电-光伏经济调度[J]. 系统仿真学报, 2022, 34(8): 1874-1884.
- [3] 丁明, 王伟胜, 王秀丽, 等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1):1-14.
- [4] 杨文海, 程华新, 高亚静, 等. 计及雾霾影响的短期光伏出力预测和负荷预测[J]. 中国电力, 2016, 49(S1): 148-153.
- [5] 于秋玲, 许长清, 李珊, 等. 基于模糊聚类和支持向量机的短期光伏功率预测[J]. 电力系统及其自动化学报, 2016, 28(12):115-118, 129.
- [6] 卢忠山, 袁建华. 基于EEMD-LSTM方法的光伏发电系统超短期功率预测[J]. 中国测试, 2022, 48(12): 125-132.
- [7] 吴雪莲, 都洪基. 基于BP神经网络-马尔科夫链的光伏发电预测[J]. 电工电气, 2014(3):22-27.
- [8] ROSATO A, PANELLA M, ARANEO R. A distributed algorithm for the cooperative prediction of power production in PV plants[J]. IEEE Transactions on Energy Conversion, 2019, 34(1):497-508.
- [9] 张娜, 任强, 刘广忱, 等. 基于VMD-GWO-ELMAN的短期光伏功率预测方法[J]. 中国电力, 2022, 55(5): 57-65.
- [10] ZHENG J Q, ZHANG H R, DAI Y H, et al. Time series prediction for output of multi-region solar power plants [J]. Applied Energy, 2020, 257 (C): 114001-114012.
- [11] 杨茂, 杨宇. 基于小波包与LSSVM的短期光伏输出功率预测研究[J]. 可再生能源, 2019, 37(11):1595-1602.
- [12] 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.
- [13] 王雁凌, 吴梦凯, 周子青, 等. 基于改进灰色关联度的电力负荷影响因素量化分析模型[J]. 电网技术, 2017, 41(6):1772-1778.
- [14] 张琪. 基于肯德尔相关系数的函数型数据相关性检验[D]. 长春:东北师范大学, 2020.
- [15] 吴杰, 王召巴, 陈友兴. 基于变分模态分解的玻纤复合材料内部缺陷特征提取方法[J]. 国外电子测量技术, 2021, 40(1):15-20.
- [16] KONSTANTIN D, DOMINIQUE Z. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [17] 孙康, 金江涛, 李春, 等. 基于优化变分模态分解与混沌分形融合的滚动轴承故障识别[J]. 动力工程学报, 2022, 42(10):951-959, 985.
- [18] 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.
- [19] 李泽宇, 郭创新, 朱承治. 采用GA-BPNN与TLS模型的风电机异常辨识方法[J]. 电力系统自动化, 2020, 44(9):95-102.
- [20] 辛宇, 陈兴, 许素安, 等. 基于GA-PSO-BP的车辆动态称重算法研究[J]. 中国测试, 2021, 47(7):26-30.
- [21] 韦海成, 王生营, 许亚杰, 等. 样本熵融合聚类算法的森林火灾图像识别研究[J]. 电子测量与仪器学报, 2020, 34(1):171-177.
- [22] 张妍, 韩璞, 王东风, 等. 基于变分模态分解和LSSVM的风电场短期风速预测[J]. 太阳能学报, 2018, 39(1): 194-202.
- [23] 付乐天, 李鹏, 高莲. 考虑样本异常值的改进最小二乘支持向量机算法[J]. 仪器仪表学报, 2021, 42(6):179-190.
- [24] 全卫国, 郭超宇, 赵如意. 基于改进麻雀算法优化LSSVM的再循环箱浆液密度预测模型[J]. 电子测量技术, 2022, 45(1):70-76.
- [25] MIRJALILI S, SEYED M M, ANDREW L. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69:46-61.
- [26] 金星, 邵珠超, 王盛慧. 一种基于差分进化和灰狼算法的混合优化算法[J]. 科学技术与工程, 2017, 17(16): 266-269.

### 作者简介

袁建华, 博士, 副教授, 主要研究方向为光电子技术应用、微电网运行与控制等。

E-mail:sd.yjh@mail.sdu.edu.cn

李洪强, 硕士研究生, 主要研究方向为光伏发电预测、多元负荷预测等。

E-mail:hqtc6263@163.com