

引用格式:邹港,赵斌,罗强,等.基于 PCA-VMD-MVO-SVM 的短期光伏输出功率预测方法[J].电力科学与技术学报,2024,39(5):163-171.

Citation: ZOU Gang, ZHAO Bin, LUO Qiang, et al. Prediction method of short-term PV output power based on PCA-VMD-MVO-SVM[J]. Journal of Electric Power Science and Technology, 2024, 39(5): 163-171.

# 基于 PCA-VMD-MVO-SVM 的短期光伏输出功率预测方法

邹港<sup>1</sup>, 赵斌<sup>1,2</sup>, 罗强<sup>1,3</sup>, 梁告<sup>4</sup>, 王力<sup>1,2</sup>

(1.长沙理工大学电气与信息工程学院,湖南长沙 410114;2.电网防灾减灾全国重点实验室,湖南长沙 410114;3.国网湖南省电力公司永州供电公司,湖南永州 425000;4.湖南红太阳新能源科技有限公司,湖南长沙 410111)

**摘要:**为了提高光伏输出功率短期预测的准确性和可靠性,提出一种基于主成分分析法(principal component analysis, PCA)、变分模态分解法(variational mode decomposition, VMD)和多元宇宙算法(multi verse optimizer, MVO)对支持向量机(support vector machine, SVM)进行优化的光伏输出功率短期预测组合模型。先利用 PCA 具有的数据分析能力和 VMD 具有的数据分解性能,对多维训练数据进行降维和分解;再将提取后的数据输入由 MVO 算法优化的 SVM 预测模型,得到不同本征模态的光伏输出功率预测分量;最后,将各预测分量的结果进行叠加。研究表明:该模型在晴天、多云和阴雨天气时的平均绝对百分比误差分别为 0.745 3%、0.510 5% 和 1.015 6%。以多云天气为例,该模型的平均绝对百分比误差比 MVO-SVM、VMD-MVO-SVM、PCA-MVO-SVM 模型的分别降低了 3.820 7%、2.917 3% 和 1.843 8%。

**关键词:**光伏发电;短期功率预测;主成分分析;变分模态分解;多元宇宙算法;支持向量机

**DOI:** 10.19781/j.issn.1673-9140.2024.05.017 **中图分类号:** TM615 **文章编号:** 1673-9140(2024)05-0163-09

## Prediction method of short-term PV output power based on PCA-VMD-MVO-SVM

ZOU Gang<sup>1</sup>, ZHAO Bin<sup>1,2</sup>, LUO Qiang<sup>1,3</sup>, LIANG Gao<sup>4</sup>, WANG Li<sup>1,2</sup>

(1.College of Electrical and Information Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2.State Key Laboratory of Disaster Prevention and Reduction for Power Grid, Changsha 410114, China; 3.Yongzhou Power Supply Company, State Grid Hunan Electric Power Co., Ltd., Yongzhou 425000, China; 4.Hunan Red Solar New Energy Science and Technology Co., Ltd., Changsha 410111, China)

**Abstract:** To enhance the accuracy and reliability of short-term photovoltaic (PV) output power forecasting, a hybrid model is proposed, which integrates principal component analysis (PCA), variational mode decomposition (VMD), and multi-verse optimizer (MVO) to optimize a support vector machine (SVM) for PV output power prediction. Initially, PCA's data analysis capabilities and VMD's data decomposition performance are leveraged to reduce the dimensionality and decompose the multidimensional training data. Subsequently, the extracted dataset is fed into an SVM prediction model optimized by the MVO algorithm to obtain PV output power forecast components for different intrinsic modes. Finally, the results of these forecast components are aggregated. The research findings indicate that the proposed model achieves mean absolute percentage errors (MAPEs) of 0.7453%, 0.5105%, and 1.0156% for sunny, partly cloudy, and rainy days, respectively. Taking partly cloudy weather as an example, the MAPE of the proposed model is reduced by 3.8207%, 2.9173%, and 1.8438% compared to the MVO-SVM, VMD-MVO-SVM, and PCA-MVO-SVM models, respectively.

**Key words:** photovoltaic power generation; short-term power prediction; principal component analysis; variational mode decomposition; multi-verse algorithm; support vector machine

收稿日期:2023-07-29;修回日期:2023-12-21

基金项目:国家自然科学基金(52107071);湖南省自然科学基金(2023JJ30048);湖南省教育厅科学研究重点项目(22A0217);长沙理工大学学术学位研究生项目(CSLGCX23155)

通信作者:赵斌(1968—),男,博士,教授,博士生导师,主要从事新能源科学技术及应用等方面的研究;E-mail:zhaobin19680507@163.com

近年来,光伏发电技术发展得十分迅速<sup>[1]</sup>。随着光伏装机容量的不断提高,其随机性、波动性和间歇性等给电网安全和电力消纳带来了挑战。光伏输出功率预测技术能有效降低光伏发电对电网产生的负面影响,为光伏并网决策提供依据<sup>[2]</sup>,是降低光伏发电不确定性影响的关键技术之一<sup>[3-4]</sup>。

根据预测方法的不同,光伏输出功率预测可分为物理方法<sup>[5]</sup>、统计方法<sup>[6]</sup>和组合方法等<sup>[7]</sup>。为提高光伏发电功率预测的准确性,研究者们对物理方法、统计方法进行了组合,集中发挥不同方法的优势<sup>[8]</sup>。文献[9]基于改进脉冲神经网络,提高算法跳出局部最优的能力,有效地提高了预测准确度。文献[10-11]在支持向量机(supporting vector machine, SVM)的基础上,提出了基于贝叶斯统计理论的机器学习方法,大幅提升了其预测模型的泛化性。文献[12]提出了基于蜻蜓优化算法的极限学习机预测模型,在提升模型特征映射的同时避免了极限学习机的过拟合问题。文献[13]采用灰狼优化算法来优化传统BP神经网络的阈值和权重,规避了在其训练过程中陷入局部最优的困境,提升了算法收敛速度。文献[14]采用原型聚类算法,将历史气象数据按天气类型进行分类,并在此基础上运用变分模态分解对每一类数据进行分解,分别对得到的子序列进行预测,再对预测结果进行叠加,提高了其算法预测精度。文献[15]通过采用主成分分析法(principal component analysis, PCA)降低数据维度,并结合遗传算法优化Elman神经网络,解决了原算法运算速度较慢的问题。文献[16]提出基于混合改进的多元宇宙算法(multi verse optimizer, MVO),并利用差分进化算法进行全局搜索,通过降低SVM随机权值和阈值的误差,有效提高了光伏输出功率短期预测的精度。

通常,影响光伏输出功率预测精度的主要因素为预测模型和训练数据的选取。MVO算法具有搭建简单、控制参数少、鲁棒性强、并行计算效能高等优点。通过MVO对SVM的初始权值和阈值进行优化,能够有效提升SVM的空间映射能力和参数寻优速度。历史气象数据之间具有多重相关性与不规则波动性,且光伏功率序列也具有非平稳性<sup>[17]</sup>,这些对预测模型的预测精度影响较大。

本文将这些方法与变分模态分解法(variational mode decomposition, VMD)相结合,提出了一种基于PCA-VMD-MVO-SVM的短期光伏输出功率预测组合模型。先利用PCA对数据进行降维,并将降

维后的数据通过VMD进行分解,原始序列被分解为不同变化趋势的模态分量<sup>[18]</sup>;再将分解后得到的各个子序列分别输入经MVO优化的SVM模型,对输出功率进行预测;最后,叠加各个预测结果,产生最终预测值。该预测组合模型综合考虑了影响光伏输出功率的环境因素和气象特征,同时兼顾了光伏输出功率的非平稳的特性。通过实例进行数值仿真与对比,该组合模型在提高光伏功率预测精度上的有效性得到了验证。

## 1 理论基础

### 1.1 主成分分析

PCA是一种常用统计分析方法,可用来抽取数据的主要特征分量<sup>[19-20]</sup>,对高维数据进行降维。其算法原理如下:

假设 $m$ 个序列集合: $x_1, x_2, \dots, x_m$ ,且存在评估主体 $n$ 个。其中,第 $i$ 个评估主体的第 $j$ 个指标为 $x_{ij}$ 。

首先,对原始数据进行归一化处理,生成单元矩阵 $X^*$ ;其次,计算相关性矩阵 $R$ ,并求解特征方程 $|\lambda I - R| = 0$ ,以获得特征值 $\lambda$ 和对应的特征子空间 $e$ ;再次,计算各特征值的贡献率,并选择贡献率较高的特征值对应的特征子空间来构建矩阵,该特征值贡献率的计算式为

$$\varphi_l = \frac{\lambda_l}{\sum_{k=1}^p \lambda_k} \times 100\%, l = 1, 2, \dots, p \quad (1)$$

最后,通过使用 $m$ 个特征子空间,对原始数据矩阵进行线性转换,即

$$\begin{cases} y_1 = e_{11}x_1 + e_{12}x_2 + \dots + e_{1p}x_p \\ y_2 = e_{21}x_1 + e_{22}x_2 + \dots + e_{2p}x_p \\ \vdots \\ y_m = e_{m1}x_1 + e_{m2}x_2 + \dots + e_{mp}x_p \end{cases} \quad (2)$$

式中, $e_{ij}$ 为原始数据矩阵第 $i$ 个特征值对应的 $j$ 维特征向量, $i=1, 2, \dots, m, j=1, 2, \dots, p; y_k$ 为第 $k$ 个分量, $k=1, 2, \dots, m$ 。

### 1.2 变分模态分解

VMD是一种处理非平稳信号的滤波方法<sup>[21]</sup>。该方法能够将原始信号 $f(t)$ 分解为具有不同中心频率和带宽的本征模态分量(intrinsic mode functions, IMF)。通过约束条件,确保每个模态具有有限的带宽和特定的中心频率分量,并将总带宽之和作为目标函数。在该模型中,要求所有模态总和等于原始信号。该模型具体如下:

$$\begin{cases} \min_{v_m, \omega_m} \left\{ \sum_m \left\| \partial_t \left[ (\delta(t) + j/\pi t) \circ v_m(t) \right] e^{-j\omega_m t} \right\|_2^2 \right. \\ \left. \text{s.t. } \sum_{m=1}^M v_m = f(t) \right. \end{cases} \quad (3)$$

式中,  $\partial_t$  为梯度计算;  $v_m$ 、 $\omega_m$  分别表示分解后第  $m$  个模态系数及其对应的中央频率;  $\delta(t)$  为单位脉冲函数;  $\circ$  为卷积算子;  $f(t)$  表示原始信号;  $t$  为时间。

引入乘子变量  $\xi$ , 将该约束最优化题转化成无约束变分问题。

VMD 主要迭代求解步骤如下。

1) 初始化  $\hat{v}_m^{(1)}$ 、 $\omega_m^{(1)}$ 、 $\xi^{(1)}$  和收敛上限  $N$ 。其中,  $\hat{v}_m^{(1)}$ 、 $\omega_m^{(1)}$ 、 $\xi^{(1)}$  分别为  $\{v_m\}$ 、 $\{\omega_m\}$ 、 $\xi$  通过交替优化算法在第 1 次交替迭代后的结果。

2) 利用交替优化算法更新  $\{v_m\}$ 、 $\{\omega_m\}$  和  $\xi$ 。

3) 通过使用精度收敛准则  $\epsilon > 0$  来判断式是否得以满足, 如果该判断式不满足, 则返回到步骤 2 进行重新迭代; 否则, 结束迭代, 并将最后一次迭代得到的  $\hat{v}_m$  和  $\omega_m$  作为最终结果输出。该判断式为

$$\sum_m \frac{\|\hat{v}_m^{(n+1)} - \hat{v}_m^{(n)}\|_2^2}{\|\hat{v}_m^{(n)}\|_2^2} < \epsilon, n < N \quad (4)$$

### 1.3 多元宇宙算法

目前, 物理学家认为宇宙起源于大爆炸。在此之前并不存在宇宙, 也不存在任何物质<sup>[22]</sup>。基于这一概念, 学者提出了一种元启发式优化算法, 即多元宇宙算法。

该算法实现主要步骤如下。

1) 设解空间存在宇宙矩阵公式为

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (5)$$

式中,  $n$  为宇宙数量;  $d$  为宇宙内物体数量;  $x_i^d$  为第  $i$  个宇宙的第  $d$  个参数。

2) 通过建立数学模型来描述白洞和黑洞之间的相互作用, 采用轮盘赌机制进行选择。在每轮迭代中, 根据宇宙的适应度进行排序, 并使用轮盘赌机制来选择一个白洞作为当前迭代的关注对象, 即

$$x_i^j = \begin{cases} x_k^j, & r_1 < N(X_i) \\ x_i^j, & r_1 \geq N(X_i) \end{cases} \quad (6)$$

式中,  $x_i^j$  为第  $i$  个宇宙的第  $j$  个参数;  $x_k^j$  为轮盘赌机制

选出第  $k$  个宇宙的第  $j$  个参数;  $r_1$  为处于 0 到 1 之间的随机数;  $N(X_i)$  为第  $i$  个宇宙的适应度。

3) 在迭代过程中, 引入自适应函数来更新概率参数  $W_{EP}$  和旅行距离  $T_{DR}$ 。  $W_{EP}$  与虫洞间存在一元单调递增函数,  $T_{DR}$  的转换距离随着迭代进行而不断缩小, 以实现更准确地局部搜索。  $W_{EP}$  和  $T_{DR}$  的表达式分别为

$$W_{EP} = \min W_{EP} + l \left( \frac{W_{EP, \max} - W_{EP, \min}}{L} \right) \quad (7)$$

$$T_{DR} = 1 - \frac{l^p}{L^p} \quad (8)$$

式(7)、(8)中,  $L$  为最大迭代轮次;  $l$  为当前迭代轮次;  $W_{EP, \min}$  和  $W_{EP, \max}$  定义了概率范围;  $p$  为迭代过程中的精度参数, 该值越高, MVO 算法的局部搜索速度越快。

4) 更新宇宙的位置并寻找最优个体。

当  $r_2 < W_{EP}$  时, 有

$$x_i^j = \begin{cases} x_j + T_{DR}((u_j - l_j)r_4 + l_j), & r_3 < 0.5 \\ x_j - T_{DR}((u_j - l_j)r_4 + l_j), & r_3 \geq 0.5 \end{cases} \quad (9)$$

当  $r_2 \geq W_{EP}$  时, 有

$$x_i^j = x_i^j \quad (10)$$

式(9)、(10)中,  $x_j$  为最优宇宙的第  $j$  个参数;  $r_2$ 、 $r_3$  和  $r_4$  均为在 0 到 1 之间的随机数;  $u_j$  和  $l_j$  分别为参数  $j$  的上、下界。

### 1.4 支持向量机

SVM 是模式分类中的一个重要工具, 被广泛用于高维空间中非线性问题<sup>[23]</sup>。

假设  $\{(x_i, y_i), i = 1, 2, \dots, n, x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}$  为高维特征空间中的训练集, 通过一个非线性映射函数  $\varphi(x)$  将该数据集映射到高维空间  $\mathbf{R}^n$  中, 其函数关系式为

$$f(x) = \omega^T \varphi(x) + b \quad (11)$$

式中,  $\omega$  为特征空间的参数向量;  $b$  为偏置项。在高维特征空间中, 寻找能使目标函数  $f(x)$  最小化的  $\omega$  和  $b$ , 即

$$\begin{cases} \min_{\omega, b} \frac{\omega^T \omega}{2} \\ \text{s.t. } \begin{cases} y_i - \omega \varphi(x_i) - b \leq \epsilon \\ \omega \varphi(x_i) + b - y_i \leq \epsilon \end{cases} \end{cases} \quad (12)$$

为估计预测点偏差大小, 引入可容许变量  $\epsilon$  和惩罚系数  $C$ , 该回归问题就变成了目标优化问题, 即

$$\left\{ \begin{array}{l} \min_{\alpha, \alpha^*} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) + \\ \quad \epsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) - \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \\ \text{s.t.} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, 0 \leq \alpha_i \leq C, \\ \quad 0 \leq \alpha_i^* \leq C \end{array} \right. \quad (13)$$

式中,  $\alpha_i, \alpha_i^*$  为拉格朗日乘子, 且  $\alpha_i \geq 0, \alpha_i^* \geq 0$ 。只有存在部分参数  $\alpha_i - \alpha_i^* \neq 0$  时, 带约束的最优值问题才转化为无限制条件的回归问题, 即 SVM。

得到的支持向量机回归函数为

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (14)$$

式中,  $K(x_i, x)$  为核函数, 其具有高分辨率, 计算量少, 实用性强的特点。核函数选用最常用的高斯核函数, 即

$$K(x_i, x) = \exp\left(-\frac{\|x - x_i\|}{\delta}\right) \quad (15)$$

式中,  $\delta$  为核函数带宽。

## 2 光伏输出功率预测组合模型设计

### 2.1 预测流程

预测模型的基本思想是利用光伏电站获取的气象数据实现对光伏输出功率的预测。预测流程主要分为以下6个部分, 具体流程如图1所示。

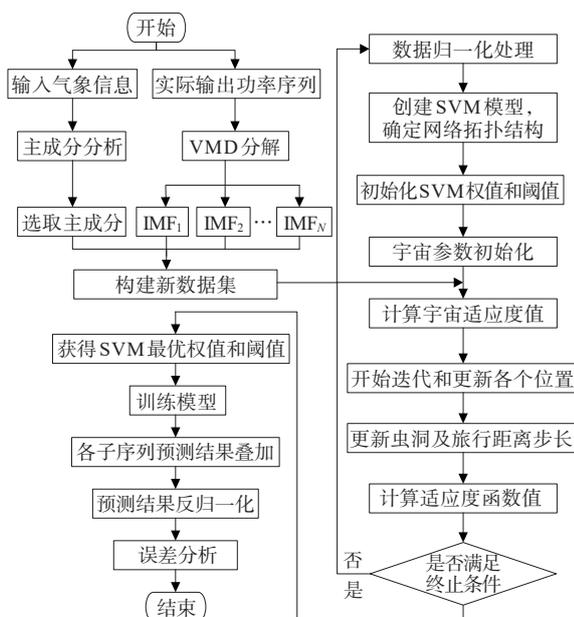


图1 基于PCA-VMD-MVO-SVM的光伏短期功率预测流程

Figure 1 Prediction flowchart of short-term PV output power based on PCA-VMD-MVO-SVM

- 1) 数据的相关性分析;
- 2) 基于PCA的气象因素分析与新特征提取;
- 3) 利用VMD, 将光伏输出功率数据分解为多个IMF;
- 4) 将新变量与各个IMF组合成新的数据集;
- 5) 将数据集输入经MVO优化后的SVM模型;
- 6) 将各子序列的预测值聚合得到最终的预测结果。

### 2.2 评价指标

为了科学有效地衡量预测光伏输出功率与实际功率之间的差距, 采用相关评价指标对模型进行评价<sup>[24]</sup>。常用的光伏输出功率预测结果评价指标包括: 平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)以及平均误差百分比(mean absolute percentage error, MAPE)。这些评价指标从不同角度对预测结果的准确性进行评估。单一的评价指标很难给出全面的评价结果。因此, 采用MAE、RMSE和MAPE这3个指标进行综合评价, 其计算式分别如下:

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |f_i - F_i| \quad (16)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - F_i)^2} \quad (17)$$

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{f_i - F_i}{F_i} \right| \times 100\% \quad (18)$$

式(16)~(18)中,  $N$  为样本数量;  $f_i$  为预测的光伏输出功率;  $F_i$  为实际的光伏输出功率。

## 3 算例分析

### 3.1 数据来源

选取某光伏电站2020年1月1日至3月31日10:30—19:45的光伏输出功率(样本的时间间隔为15 min)与这段时间的历史气象数据(共计3 458组)为研究对象。

### 3.2 数据相关性分析

影响光伏输出功率的环境因素有太阳辐照度、组件温度和环境温度等, 且各因素之间具有一定的耦合性。在进行光伏输出功率预测时, 若考虑全部因素, 会降低预测模型精度并显著提高预测复杂度。为提高光伏输出功率的预测准确性, 需要对气象因素进行筛选, 选择对其影响较为显著的因素。因此, 为了评估不同气象因素与光伏输出功率之间的关联性, 使用Pearson相关系数对其进行评估<sup>[25]</sup>,

Pearson 相关系数  $r$  的计算式如下:

$$r = \frac{\sum_{i=1}^a (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^a (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^a (Y_i - \bar{Y})^2}} \quad (19)$$

式中,  $a$  为样本容量;  $X_i, \bar{X}$  分别为气象因素与其均值;  $Y_i, \bar{Y}$  分别为光伏输出功率与其均值。

计算得到的相关性系数见表1。由表1可知,总辐照度和法向直射辐照度与光伏输出功率具有显著的正相关关系,水平面散射辐照度与光伏输出功率之间的正相关性较弱。此外,相对湿度与光伏输出功率具有显著的负相关关系,气温和气压与光伏输出功率数据之间的相关程度较低。

表1 气象因素与光伏输出功率的 Pearson 相关系数

Table 1 Pearson correlation coefficient between meteorological factors and photovoltaic output power

影响因素	Pearson 相关系数
气压	-0.089
气温	-0.031
相对湿度	-0.513
总辐照度	0.836
法向直射辐照度	0.710
水平面散射辐照度	0.335

Pearson 相关系数仅反映了输入变量与光伏输出功率之间的线性相关性,不能反映输入变量之间是否存在非线性相关关系。因此,仅通过 Pearson 相关系数法来减少冗余变量与降低数据的维度是不够严谨的。

为更好地处理变量之间的相关性,降低数据输入的维度和复杂度,采用 PCA 对数据进行处理。PCA 可通过分析提取出新的特征,降低各个数据之间的相关性,优化光伏输出功率预测模型的输入样本,更准确地选择和利用气象因素,提高光伏功率预测模型的准确性和可靠性。

### 3.3 主成分提取

利用 SPSS 统计分析软件对这 6 个气象变量进行抽样适合性检验,该模型的检验值为 0.691。这表明各气象变量之间存在较强的相关性,符合进行主成分分析的条件。该主成分特征值和累计方差贡献见表2,这 6 个主成分因子特征值碎石图如图2所示。从图2中可看出,前 3 个主成分的特征值均大于 1,且这 3 个主成分的特征值总共解释了原始数据

89.470% 的方差。因此,可以选择这 3 个主成分因子(成分 1、2、3)来替代原始的气象变量,实现数据的降维。

表2 主成分特征值与方差贡献率

Table 2 Principal component eigenvalue and variance contribution rate

成分	特征值	方差百分比/%	累计贡献率/%
1	2.137	35.620	35.620
2	1.530	25.505	61.125
3	1.091	18.184	89.470
4	0.909	15.154	94.464
5	0.282	4.706	99.169
6	0.050	0.831	100.000

通过使用主成分分析方法,能够更好地利用少数几个主成分因子来代表原始数据集的信息,减少数据的复杂度和维度。这样可以简化模型的建立和分析过程,并且在保留数据最重要信息的同时,提高预测模型的精度和可解释性。

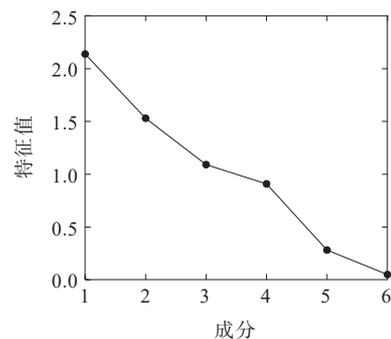


图2 主成分因子特征值碎石图

Figure 2 Scree plot of principal component eigenvalues

### 3.4 输出功率序列分解重构

由于光伏输出功率存在的波动性和周期性,故非平稳的信号会对预测结果产生较大影响<sup>[26]</sup>。针对这一技术难题,采用 VMD,将复杂的光伏输出功率信号分解成多个具有不同频率且相对平稳的子序列。这种分解能够更好地帮助理解和捕捉光伏输出功率的波动性和周期性,提高预测模型的准确性。原始数据与 VMD 分解结果如图3所示。

在进行 VMD 分解时,通过多次尝试并进行寻优后,设定 VMD 分解的子序列数  $M$  为 7。从图3中可以看出,光伏输出功率信号的分解效果。

使用 VMD 方法对光伏输出功率进行分解,可以有效地提取不同频率的成分,并且保持子序列的相对平稳。这为后续的预测组合模型构建和分析提供了更准确和可靠的输入数据。

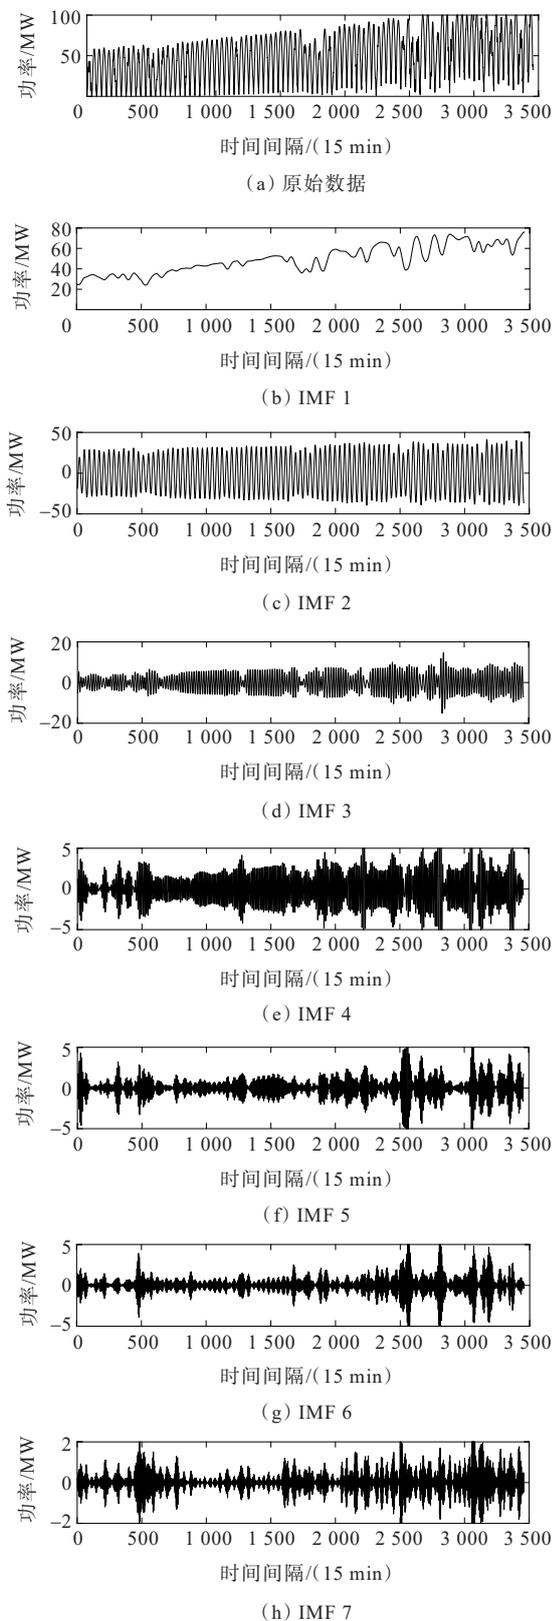


图3 原始数据与VMD分解结果

Figure 3 Original data and VMD decomposition results

3.5 评价与分析

为验证本文提出的预测组合模型的性能以及PCA降维的必要性和VMD分解的有效性,在相同

的训练参数和数据集条件下,构建传统BP神经网络(模型1)、SVM模型(模型2)、MVO-SVM模型(模型3)、VMD-MVO-SVM模型(模型4)以及PCA-MVO-SVM模型(模型5)来与PCA-VMD-MVO-SVM模型(模型6)进行训练和测试。

通过对这些模型进行比较分析,评估不同模型的预测性能,并验证本文提出的PCA-VMD-MVO-SVM模型(模型6)在光伏输出功率预测中的优越性。各模型预测对比与误差对比分别如图4、5所示。不同模型的预测结果见表3。

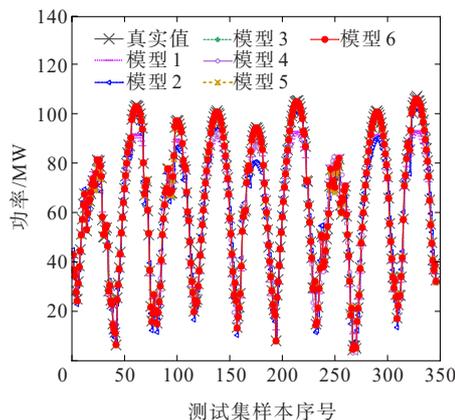


图4 各模型预测对比

Figure 4 Comparison of model predictions

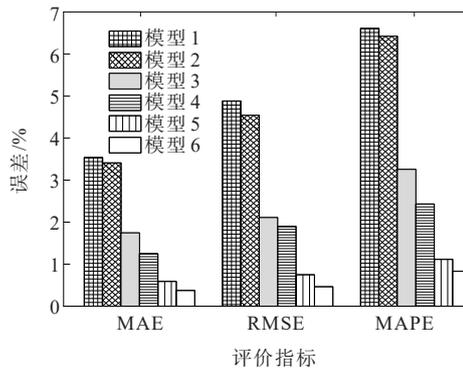


图5 各模型误差对比

Figure 5 Comparison of errors from different models

表3 不同模型的预测结果

Table 3 Prediction results of different models %

模型	MAE	RMSE	MAPE
1	3.534 9	4.882 3	6.608 4
2	3.408 1	4.543 1	6.424 1
3	1.743 6	2.109 3	3.254 6
4	1.246 3	1.897 4	2.431 3
5	0.589 7	0.748 2	1.113 6
6	0.373 8	0.462 4	0.832 3

通过图 5 和表 3 的结果可以得出,PCA-VMD-MVO-SVM 预测组合模型(模型 6)在性能指标方面表现最佳,其误差指标均优于其他模型的。相比之下,未经优化的传统 BP 神经网络(模型 1)和 SVM 模型(模型 2)的预测精度较低。然而,采用 MVO 优化 SVM 模型(模型 2)的精度与 SVM 模型(模型 1)的高,即组合算法相较于单一算法的预测精度明显提高。此外,由图 4、5 与表 3 还可知,本文提出的数据分析提取方法进一步提高了 MVO-SVM 的预测精度。

为测试该预测方法在不同天气类型下的预测性能,选择 2020 年 3 月 1 日(阴雨)、3 月 3 日(多云)和 3 月 5 日(晴天)的数据,并根据预测日的天气类型分别选取了相近的 5 天作为训练样本。从图 5 中可以看出,可以明显观察到传统 BP 神经网络(模型 1)和单一 SVM 模型(模型 2)的预测精度较低。因此,后续采用模型 3、模型 4、模型 5 和模型 6 来对不同天气类型进行预测,预测结果如图 6~8 所示。

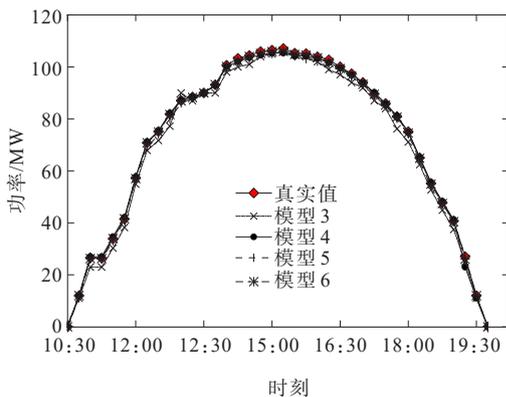


图 6 晴天光伏输出功率预测结果

Figure 6 Prediction results of PV output power on sunny day

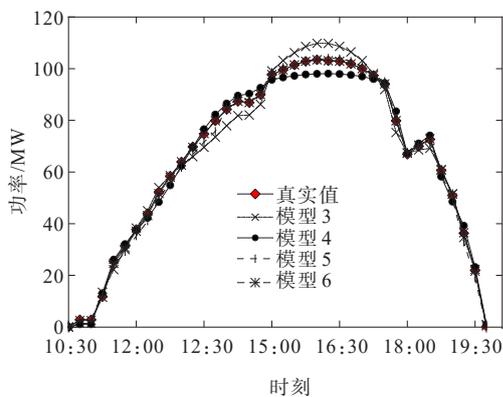


图 7 多云天气光伏输出功率预测结果

Figure 7 Prediction results of PV output power under cloudy weather

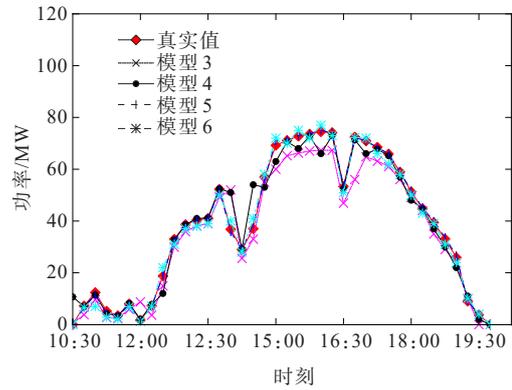


图 8 阴雨天光伏输出功率预测结果

Figure 8 Prediction results of PV output power on rainy day

晴天光伏输出功率的波动相对较小。从图 6 中可看出,可以发现这 4 种模型在上午和下午都展现出良好的预测效果。但经过降维和特征提取后的 PCA-VMD-MVO-SVM 模型(模型 6)的预测效果更优于单纯的 MVO-SVM 模型(模型 3)的。

在多云的气象条件下,天空中云朵覆盖度的变化速度快,影响了太阳辐射直接照射到光伏板上的时间和强度,导致光伏输出功率曲线波动较大。

从图 7 中可以看出,PCA-MVO-SVM 模型(模型 5)和 PCA-VMD-MVO-SVM 模型(模型 6)的预测轨迹大致相同,模型 6 相对于 PCA-MVO-SVM 模型(模型 5)具有更小的误差。这表明在对光伏的输出功率进行处理后,预测结果的平稳性更好。从不同算法在输出功率较高数值段的差异可以明显看出,MVO-SVM 数据处理方法对预测模型的重要性。

阴雨天的云层覆盖导致光伏板接收到的太阳辐射量减少,同时,大气温度较低,相对湿度较高。在阴雨气象条件下,光伏发电量波动较大,使得准确的预测变得困难。从图 8 中可以看出,本文提出的模型在曲线的稳定段和突变转折阶段都与实际输出功率曲线更吻合。

这 3 种天气条件下各模型评价指标见表 4。通过对这 4 种模型的误差指标进行分析,并结合仿真图的对比,可以得出:在这 3 种天气类型中,PCA-VMD-MVO-SVM 模型的误差评估值最小。这进一步验证了该组合模型中数据分析提取的合理性和重要性,它使得模型在不同气象条件下具有更高的预测精度和平稳性。

表4 不同天气条件下的模型预测评估

Table 4 Evaluation of model predictions under different weather conditions %

天气	模型	MAE	RMSE	MAPE
晴天	3	2.472 3	2.745 6	3.561 7
	4	0.605 5	0.923 4	1.256 3
	5	0.955 7	1.150 7	1.937 4
	6	0.384 5	0.498 3	0.745 3
多云	3	2.838 8	3.544 2	4.331 2
	4	2.294 1	2.737 6	3.427 8
	5	1.379 8	1.759 9	2.354 3
	6	0.224 5	0.345 7	0.510 5
阴雨天	3	4.406 9	5.573 8	6.294 7
	4	2.782 1	4.819 4	5.945 7
	5	1.731 8	2.097 8	3.112 8
	6	0.443 4	0.632 4	1.015 6

## 4 结语

本文提出了基于PCA-VMD-MVO-SVM的光伏功率预测组合模型,并通过仿真进行了算例对比分析,得出如下结论:

1) 利用PCA可以提取出相互独立的影响因子,降低模型输入变量的维度。通过仿真结果和实际数据对比,观察到在多云和阴雨天气情况下,PCA-MVO-SVM模型(模型5)相较于MVO-SVM模型(模型3)减小了1%和2%的MAPE,表明PCA有助于减小预测误差。

2) 利用VMD将光伏序列分解为多个子序列,每个子序列具有不同的尺度特征。通过仿真图与实际数据对比,观察到VMD-MVO-SVM模型(模型4)在阴雨天气下的MAPE相较于MVO-SVM模型(模型3)的减小了3.1819%,验证了VMD具有提高光伏输出功率的非晴空预测能力。

3) 采用MVO可以有效提升SVM参数寻优能力,并将PCA和VMD与MVO-SVM相结合,提出了PCA-VMD-MVO-SVM预测组合模型。与传统BP神经网络(模型1)、SVM(模型2)、MVO-SVM(模型3)、VMD-MVO-SVM(模型4)和PCA-MVO-SVM(模型5)这5种预测模型相比,该预测组合模型在误差评估指标(MAE、RMSE、MAPE)上均取得了最小值,该方法有效提高了预测精度。

## 参考文献:

[1] 朱琼锋,李家腾,乔骥,等.人工智能技术在新能源功率预测的应用及展望[J].中国电机工程学报,2023,43(8):

3027-3048.

ZHU Qiongfeng, LI Jiateng, QIAO Ji, et al. Application and prospect of artificial intelligence technology in renewable energy forecasting[J]. Proceedings of the CSEE,2023,43(8):3027-3048.

[2] 王玉庆,徐飞,刘志坚,等.基于动态关联表征与图网络建模的分布式光伏超短期功率预测[J].电力系统自动化,2023,47(20):72-82.

WANG Yuqing, XU Fei, LIU Zhijian, et al. Ultra-short-term power forecasting of distributed photovoltaic based on dynamic correlation characterization and graph network modeling[J]. Automation of Electric Power Systems,2023,47(20):72-82.

[3] GUO M, CAI S K. Impact of green innovation efficiency on carbon peak: carbon neutralization under environmental governance constraints[J]. International Journal of Environmental Research and Public Health, 2022,19(16):10245.

[4] 朱显辉,于越,师楠,等.BP神经网络的分层优化研究及其在风电功率预测中的应用[J].高压电器,2022,58(2):158-163+170.

ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP neural network and its application in wind power prediction[J]. High Voltage Apparatus,2022,58(2):158-163+170.

[5] YANG D Z, WANG W T, GUEYMARD C A, et al. A review of solar forecasting, its dependence on atmospheric sciences and implications for grid integration: towards carbon neutrality[J]. Renewable and Sustainable Energy Reviews,2022,161:112348.

[6] WANG K J, QI X X, LIU H D. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. Applied Energy, 2019, 251:113315.

[7] MAYER M J, GRÓF G. Extensive comparison of physical models for photovoltaic power forecasting[J]. Applied Energy,2021,283:116239.

[8] 王鹏翔,沈娟,王菁昉,等.基于PCA-LMD-WOA-ELM的短期光伏功率预测[J].智慧电力,2022,50(6):72-78.

WANG Pengxiang, SHEN Juan, WANG Jingyang, et al. Short term photovoltaic power prediction based on PCA-LMD-WOA-ELM[J]. Smart Power,2022,50(6):72-78.

[9] 董志强,郑凌蔚,苏然,等.一种基于IGWO-SNN的光伏出力短期预测方法[J].电力系统保护与控制,2023,51(1):131-138.

DONG Zhiqiang, ZHENG Lingwei, SU Ran, et al. An IGWO-SNN-based method for short-term forecast of photovoltaic output[J]. Power System Protection and Control,2023,51(1):131-138.

[10] 王清亮,杨博,应欣峰,等.非晴空条件下光伏发电短期功率预测方法[J].太阳能学报,2022,43(3):188-196.

- WANG Qingliang, YANG Bo, YING Xinfeng, et al. Short-term photovoltaic power forecasting method under non-clear sky condition[J]. *Acta Energetica Solaris Sinica*, 2022, 43(3):188-196.
- [11] 宋玮琼, 赵成, 郭帅, 等. 考虑天气类型和历史相似日的短期光伏输出功率预测[J]. *电网与清洁能源*, 2023, 39(2):75-82.
- SONG Weiqiong, ZHAO Cheng, GUO Shuai, et al. Short-term forecasting of photovoltaic output power considering weather type and historical similar days[J]. *Power System and Clean Energy*, 2023, 39(2):75-82.
- [12] 魏铭琦, 张天瑞, 高秀秀, 等. 基于DA-RKELM算法的光伏发电功率预测方法[J]. *系统仿真学报*, 2020, 32(10):2041-2051.
- WEI Mingqi, ZHANG Tianrui, GAO Xiuxiu, et al. A photovoltaic power forecasting method based on DA-RKELM algorithm[J]. *Journal of System Simulation*, 2020, 32(10):2041-2051.
- [13] 文爽, 马逸骋, 孙志强. 基于GWO-EEMD-BP神经网络的光伏发电功率短期预测[J]. *中南大学学报(自然科学版)*, 2022, 53(12):4799-4808.
- WEN Shuang, MA Yicheng, SUN Zhiqiang. Short-term prediction of photovoltaic power based on GWO-EEMD-BP[J]. *Journal of Central South University (Science and Technology)*, 2022, 53(12):4799-4808.
- [14] 张娜, 任强, 刘广忱, 等. 基于VMD-GWO-ELMAN的光伏功率短期预测方法[J]. *中国电力*, 2022, 55(5):57-65.
- ZHANG Na, REN Qiang, LIU Guangchen, et al. PV power short-term forecasting method based on VMD-GWO-ELMAN[J]. *Electric Power*, 2022, 55(5):57-65.
- [15] 胡兵, 詹仲强, 陈洁, 等. 基于PCA-GA-Elman的短期光伏出力预测研究[J]. *太阳能学报*, 2020, 41(6):256-263.
- HU Bing, ZHAN Zhongqiang, CHEN Jie, et al. Prediction research on short-term photovoltaic output based on pca-ga-Elman[J]. *Acta Energetica Solaris Sinica*, 2020, 41(6):256-263.
- [16] 马骏, 江锐, 丁倩, 等. 基于多元宇宙优化支持向量机的短期光伏发电功率预测[J]. *热力发电*, 2020, 49(4):87-92.
- MA Jun, JIANG Rui, DING Qian, et al. Prediction of short-term photovoltaic generation power based on HIMVO-SVM[J]. *Thermal Power Generation*, 2020, 49(4):87-92.
- [17] 叶林, 程文丁, 李卓, 等. 光伏集群有功功率分层预测控制策略[J]. *电力系统自动化*, 2023, 47(2):42-52.
- YE Lin, CHENG Wending, LI Zhuo, et al. Hierarchical prediction control strategy of active power for photovoltaic cluster[J]. *Automation of Electric Power Systems*, 2023, 47(2):42-52.
- [18] 夏志凌, 胡凯波, 刘心悦, 等. 基于变模态分解的异步电机转子断条故障诊断[J]. *电工技术学报*, 2023, 38(8):2048-2059.
- XIA Zhiling, HU Kaibo, LIU Xinyue, et al. Fault diagnosis of rotor broken bar in induction motor based on variable mode decomposition[J]. *Transactions of China Electrotechnical Society*, 2023, 38(8):2048-2059.
- [19] 檀晓林, 胡诗尧, 张菁, 等. 基于主成分分析与加权TOPSIS的县域配电网投资效益评估方法[J]. *电力科学与技术学报*, 2022, 37(3):133-139.
- TAN Xiaolin, HU Shiyao, ZHANG Jing, et al. Investment benefit assessment based on PCA and weighted TOPSIS in county distribution network[J]. *Journal of Electric Power Science and Technology*, 2022, 37(3):133-139.
- [20] 邹程欢, 贺民, 龚明波, 等. 基于极限区间与改进PCA-SOM的电气运行参数对专变健康影响的量化评价方法[J]. *电力系统保护与控制*, 2021, 49(17):101-108.
- WU Chenghuan, HE Min, GONG Mingbo, et al. Quantitative evaluation based on limit interval and improved PCA-SOM of electrical operating parameter health status of a special transformer[J]. *Power System Protection and Control*, 2021, 49(17):101-108.
- [21] WANG X H, SUI G Z, XIANG J W, et al. Multi-domain extreme learning machine for bearing failure detection based on variational modal decomposition and approximate cyclic correntropy[J]. *IEEE Access*, 2019, 8:197711-197729.
- [22] LI L L, WEN S Y, TSENG M L, et al. Renewable energy prediction: a novel short-term prediction model of photovoltaic output power[J]. *Journal of Cleaner Production*, 2019, 228:359-375.
- [23] 武昕, 严萌, 郭一凡, 等. 基于结构化特征图谱的组合支持向量机非侵入式负荷辨识[J]. *电力系统自动化*, 2022, 46(12):210-219.
- WU Xin, YAN Meng, GUO Yifan, et al. Non-intrusive load identification by combined support vector machine based on structured characteristic spectrum[J]. *Automation of Electric Power Systems*, 2022, 46(12):210-219.
- [24] 林铮, 刘可真, 沈赋, 等. 考虑海上风电多机组时空特性的超短期功率预测模型[J]. *电力系统自动化*, 2022, 46(23):59-66.
- LIN Zheng, LIU Kezhen, SHEN Fu, et al. Ultra-short-term power prediction model considering spatial-temporal characteristics of offshore wind turbines[J]. *Automation of Electric Power Systems*, 2022, 46(23):59-66.
- [25] 刘雨佳, 樊艳芳, 白雪岩, 等. 基于特征交叉机制和误差补偿的风力发电功率短期预测[J]. *电工技术学报*, 2023, 38(12):3277-3288.
- LIU Yujia, FAN Yanfang, BAI Xueyan, et al. Short-term wind power prediction based on feature crossover mechanism and error compensation[J]. *Transactions of China Electrotechnical Society*, 2023, 38(12):3277-3288.
- [26] 陈瑶, 陈晓宁. 基于自适应Kmeans和LSTM的短期光伏发电功率预测[J]. *电测与仪表*, 2023, 60(7):94-99.
- Chen Yao, Chen Xiaoning. Prediction of short-term photovoltaic power generation based on adaptive Kmeans and LSTM[J]. *Electrical Measurement & Instrumentation*, 2023, 60(7):94-99.