

文章编号:1001-2060(2023)09-0131-10

基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的光伏发电功率预测

王 瑞,王英洲,逯 静

(1. 河南理工大学 电气工程与自动化学院,河南 焦作 454000;
2. 河南理工大学 计算机科学与技术学院,河南 焦作 454000)

摘要:为了提高光伏发电功率预测精度,建立了基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的光伏发电功率超短期组合预测模型。首先,根据 Pearson 相关性分析,确定光辐照度、环境温度以及湿度为光伏发电功率的关键气象影响因素,继而使用改进的自适应白噪声完备集成经验模态分解(Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise,ICEEMDAN)对历史光伏功率和气象因素进行分解,降低其复杂度和随机波动性,并利用动态时间弯曲(Dynamic Time Warping,DTW)算法确定每个光伏功率子序列的输入特征向量。其次,对最小二乘支持向量机(Least Squares Support Vector Machine,LSSVM)在建模过程中的误差进行权重分配,得到加权最小二乘支持向量机(Weighted Least Squares Support Vector Machine,WLSSVM),其解决了 LSSVM 模型鲁棒性低的缺陷。最后,通过改进黏菌算法(Improve Slime Mould Algorithm,ISMA)对 WLSSVM 进行参数优化,搭建 ISMA-WLSSVM 预测模型,并在多种不同天气类型下进行光伏发电功率预测仿真实验。实验证明:相比 EOSSA-ELM 预测模型,该模型的 RMSE 在晴天、多云和雨天分别降低了 57.4%、57.5% 和 52.5%。

关键词:光伏发电预测;动态时间弯曲算法;黏菌算法;加权最小二乘支持向量机;ICEEMDAN

中图分类号:TM615 文献标识码:A DOI:10.16146/j.cnki.rndlge.2023.09.016

[引用本文格式] 王 瑞,王英洲,逯 静. 基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的光伏发电功率预测[J]. 热能动力工程,2023,38(9):131-140. WANG Rui, WANG Ying-zhou, LU Jing. Prediction of photovoltaic power generation based on ICEEMDAN-DTW and ISMA-WLSSVM[J]. Journal of Engineering for Thermal Energy and Power,2023,38(9):131-140.

Prediction of Photovoltaic Power Generation based on ICEEMDAN-DTW and ISMA-WLSSVM

WANG Rui, WANG Ying-zhou, LU Jing

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo, China, Post Code: 454000;
2. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo, China, Post Code: 454000)

Abstract: In order to improve the prediction accuracy of photovoltaic power generation, an ultra-short-term combined prediction model of photovoltaic power generation based on ICEEMDAN-DTW and ISMA-WLSSVM was proposed. Firstly, according to Pearson correlation analysis, light irradiance, ambient temperature and humidity were determined to be the key meteorological factors affecting photovoltaic power generation, then, an improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) was used to decompose the historical PV power and meteorological factors and reduce

收稿日期:2022-11-22; 修訂日期:2022-12-27

基金项目:国家自然科学基金(62273133);河南省科技攻关项目(222102210120)

Fund-supported Project:National Natural Science Foundation of China (62273133); Henan Province Science and Technology Research Project (222102210120).

作者简介:王 瑞(1977-),男,河南理工大学副教授.

their complexity and random volatility, and the dynamic time warping (DTW) algorithm was used to determine the input eigenvectors of each PV power subsequence. Secondly, the weighted least squares support vector machine (WLSSVM) was obtained by assigning weights to the errors in the modeling process of least squares support vector machine (LSSVM), which solved the defect of low robustness of LSSVM model. Finally, the parameters of WLSSVM were optimized through the improved slime mould algorithm (ISMA), the ISMA-WLSSVM prediction model was built, and the photovoltaic power generation prediction simulation experiment was conducted under various weather types. Experimental results show that compared with the EOSSA-ELM prediction model, this model reduces RMSE by 57.4%, 57.5% and 52.5% on sunny, cloudy and rainy days, respectively.

Key words: photovoltaic power prediction, dynamic time warping (DTW) algorithm, slime mould algorithm, weighted least squares support vector machine (WLSSVM), ICEEMDAN

引言

为实现“双碳”目标,我国正加速推进构建以新能源为主体的新型电力系统^[1]。其中,太阳能既是清洁能源,又是可再生能源^[2],已成为全球能源转型的重要领域。因此,实现光伏发电功率的精准预测,对电网的合理调度、安全运行以及系统的稳定有着重大意义^[3-4]。

光伏发电功率预测方法分为物理模型预测法和时程统计预测法。物理模型预测法先预测出太阳辐射强度,再结合其他信息搭建出光伏发电功率的预测模型,完成对光伏发电功率的预测^[5]。由于现有条件的局限性及建模的复杂性,故通常采用时程统计预测法。文献[6]采用皮尔逊相关理论对光伏功率的影响因素进行降维,结合径向基神经网络实现对光伏功率的预测。但神经网络需要大量样本数据且极易陷入局部最优^[7],而支持向量机(Support Vector Machine, SVM)在小样本回归的预测中表现非常优秀。文献[8]结合 Kmeans 算法与 SVM 预测模型,搭建了基于 Kmeans-SVM 的光伏发电功率预测模型;为了降低光伏发电功率的复杂度和随机波动性,进一步提高预测精度,文献[9]对历史光伏发电功率序列进行小波分解,将分解得到的子序列分别用于搭建 LSSVM 回归预测模型;文献[10]对历史光伏发电功率序列进行经验模态分解,将分解的每个子序列结合气象因素搭建各自的 LSSVM 回归预测模型。但是依靠经验选取预测模型超参数的方

法不能深度挖掘模型的预测性能,导致该方法下模型预测性能受到限制;文献[11]结合变分模态分解(Variational Mode Decomposition, VMD)和改进灰狼算法,搭建了基于 VMD-SE 和优化支持向量机的光伏功率预测模型,但该文献所用改进灰狼算法的寻优能力一般且只有当误差变量符合高斯分布时才能使 LSSVM 的预测精度达到最优。除此之外,序列分解组合模型在预测光伏发电功率时出现分解后的光伏发电功率各子序列与原气象因素相关性不强的问题,这也是限制模型预测精度的主要原因之一。

针对上述问题,本文提出了基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的超短期光伏发电功率组合预测模型。主要预测流程如下:(1)通过 Pearson 相关性分析,确定光伏发电功率预测模型的输入气象特征因素为光辐照度、环境温度以及湿度;(2)对历史光伏功率和关键气象影响因素均进行 ICEEMDAN 分解,并利用 DTW 确定每个光伏功率子序列的最佳输入特征向量,不仅大幅度加强了其相关性,还解决了维度暴增导致在预测过程中出现过拟合和速度相对较慢的问题;(3)WLSSVM 通过对 LSSVM 建模过程中的误差进行赋权,改善了原 LSSVM 的预测性能和鲁棒性,并利用改进黏菌算法对 WLSSVM 的参数进行优化,搭建了 ISMA-WLSSVM 预测模型;(4)将各子序列得到的光伏发电功率预测值相加,得到最终的光伏发电功率预测值。仿真结果表明,该预测方法具有更好的预测性能。

1 光伏发电功率训练样本集的构建

1.1 光伏发电功率的影响因素分析

为了能清晰地认识不同环境因素与光伏功率之间的相关关系,以便确定光伏发电功率的输入特征变量,采用 Pearson 相关系数计算各环境因素与功率之间的相关系数^[12],分析结果如图 1 所示。

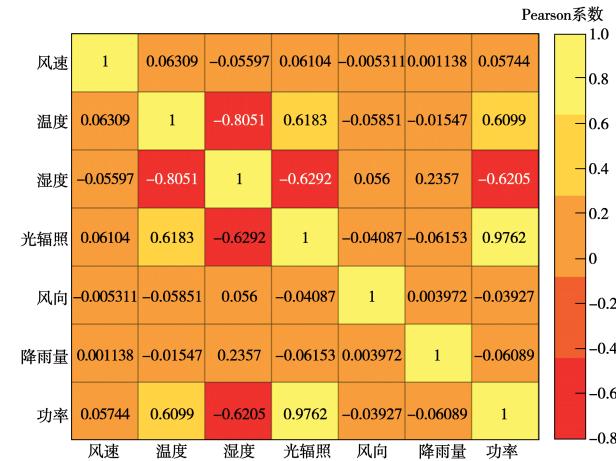


图 1 各环境因素的 Pearson 系数

Fig. 1 Pearson coefficient of each environmental factor

根据图 1 的结果,选择光辐照度、温度以及湿度作为光伏发电功率预测的关键特征因素。又由于天气类型对光伏发电功率的影响尤为明显,故选择在晴天、多云及雨天分别对光伏发电功率做预测仿真实验。

1.2 ICEEMDAN

传统的光伏发电功率预测方法难以准确地预测光伏功率的突变,导致模型的预测结果不够精确,而将光伏发电功率分解成多个具有不同频率的分量,再分别搭建预测模型进行预测,是一种非常有效且可行的解决办法。其中,自适应白噪声完备集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)是在经验模态分解(Empirical Mode Decomposition, EMD)的基础上改进得到,有效克服了 EMD 分解后的分量存在模态混叠的现象,但分解得到的各分量中仍含有噪声以及存在伪模态。所以选取白噪声被 EMD 分解后的第 k 个模态分量 IMF 来代替 CEEMDAN 在分解过程中直接添加高斯白噪声,得到改进后的

ICEEMDAN 分解方法。ICEEMDAN 分解的具体步骤为:

(1) 将 1 组白噪声 $w^i(t)$ 加入到光伏发电功率序列 $x(t)$ 中,由 $x_1^i(t) = x(t) + \zeta_0 E_1(w^i(t))$ 构造出该组白噪声 $w^i(t)$ 所对应的序列 $x_1^i(t)$,进而得到第 1 个残差分量 $r_1(t)$:

$$r_1(t) = \langle N(x_1^i(t)) \rangle \quad (1)$$

式中: $N(x_1^i(t))$ —求信号序列 $x_1^i(t)$ 的局部均值。

(2) 计算第 1 个模态分量 IMF_1 :

$$\text{IMF}_1 = x(t) - r_1(t) \quad (2)$$

(3) 构造序列 $x_2^i(t) = r_1(t) + \zeta_1 E_2(w^i(t))$, 得到第 2 个残差分量 $r_2(t) = \langle N(x_2^i(t)) \rangle$, 计算得到第 2 个模态分量 IMF_2 :

$$\text{IMF}_2 = r_1(t) - r_2(t) \quad (3)$$

式中: $E_2(\cdot)$ —由 EMD 分解白噪声 $w^i(t)$ 产生的第 2 个 IMF 分量; ζ_1 —加入噪声的信噪比与该噪声分量 $E_2(\cdot)$ 标准差之比; $N(x_2^i(t))$ —求信号序列 $x_2^i(t)$ 的局部均值。

(4) 重复步骤(3),则第 k 个残差分量 $r_k(t)$ 与模态分量 IMF_k 为:

$$r_k(t) = \langle N(r_k(t) + \zeta_{k-1} E_k(w^i(t))) \rangle \quad (4)$$

$$\text{IMF}_k = r_{k-1}(t) - r_k(t) \quad (5)$$

1.3 IMF 输入特征向量的构建

对光伏发电功率进行分解,得到一系列子序列 IMF。此时,出现原气象因素的变化并不能正确反映 IMF 变化,即原气象因素与 IMF 的关联度低的问题。故对历史气象因素也进行 ICEEMDAN 分解,得到一系列子序列 IMF,但分解后出现输入维度暴增的问题,为了保证在预测精度得到提高的同时,解决过拟合的问题并保持相对较快的预测速度,必需对一系列的 IMF 进行筛选,选取对 IMF 影响有效且具有代表的 1 组特征向量。因此,引入动态时间弯曲算法 DTW^[13] 来确定 IMF 的输入特征向量。DTW 的具体原理如下:

定义两个时间序列分别为 $x = (x_1, x_2, x_3, \dots, x_n)$ 和 $y = (y_1, y_2, y_3, \dots, y_m)$,先计算 x 与 y 之间的距离矩阵 D ,其表达式为:

$$\mathbf{D} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1m} \\ d_{21} & d_{22} & \cdots & d_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \cdots & d_{nm} \end{bmatrix} \quad (6)$$

式中: $d_{ij} = |x_i - y_j|$ — x_i 与 y_j 之间的距离。

弯曲路径为 $\mathbf{p} = \{p_1, p_2, p_3, \dots, p_r, \dots, p_k\}$, 元素 $p_r = (i, j) = d_{ij}$, 对路径做如下约束条件:

$$\begin{cases} \max(m, n) \leq k \leq m + n - 1 \\ p_1 = (1, 1) \\ p_k = (n, m) \\ p_a = (a_i, b_i), p_{a+1} = (a_{i+1}, b_{i+1}), \\ 0 \leq a_{i+1} - a_i \leq 1, 0 \leq b_{i+1} - b_i \leq 1 \end{cases} \quad (7)$$

式中: (i, j) — \mathbf{D} 中元素的坐标; p_{a+1} — p_a 的下 1 个路径点; (a_i, b_i) 与 (a_{i+1}, b_{i+1}) 依次为 p_a 和 p_{a+1} 的坐标。

通过递归算法算出所有符合条件路径的累积距离, 则所有路径的累积距离最小值就是 DTW 距离。

2 基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的光伏发电功率预测模型的搭建

2.1 ISMA-WLSSVM 预测模型的搭建

2.1.1 WLSSVM

LSSVM 在处理小样本非线性回归预测问题方面非常优秀, 故常用在光伏发电功率预测领域^[14]。但该模型在训练过程中每次的预测都需要所有训练数据参与, 仅当误差变量 e_i 符合高斯分布时预测精度才最优, 限制了 LSSVM 模型的鲁棒性。为了解决上述问题, 对 LSSVM 中的每个误差序列 e_i ($e_i \geq 0$) 都分配 1 个对应的权重 v_i ^[15], 得到 WLSSVM。WLSSVM 原理为: 设某一训练集为 $\{(x_1, y_1), \dots, (x_n, y_n)\}$, 其中, $x_i \in \mathbf{R}^k$ 为输入变量, $y_i \in \mathbf{R}$ 为函数的输出, n 为样本容量。利用非线性映射 $\varphi: \mathbf{R}^k \rightarrow \mathbf{R}^l$ ($k \leq l$) 将低维空间中的样本数据映射到高维空间。在这个高维特征空间中, 建立描述输入变量与输出之间关系的函数, 即回归函数:

$$f(x) = \mathbf{w}^T \varphi(x) + b \quad (8)$$

式中: \mathbf{w} —权值; b —偏置量。

通过结构风险最小化原则, WLSSVM 回归问题转化为下式的约束优化问题:

$$\begin{cases} \min J(\mathbf{w}, \varepsilon) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^m v_i e_i^2 \\ y_i = \mathbf{w}^T \varphi(x_i) + b + e_i, i = 1, 2, \dots, n \end{cases} \quad (9)$$

式中: γ —正则化因子 ($\gamma > 0$); e_i —误差序列; v_i —误差 e_i 对应的权重。

引入拉格朗日乘子得:

$$L = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \gamma \sum_{i=1}^{i=n} v_i e_i^2 + \sum_{i=1}^{i=n} a_i (\mathbf{w}^T \varphi(x_i) + b + e_i - y_i) \quad (10)$$

式中: a_i —拉格朗日乘子 ($i = 1, 2, \dots, n, a_i \geq 0$)。

根据 KKT 条件和 Mercer 条件, 最终可得 WLSSVM 的回归函数:

$$f(x) = \sum_{i=1}^{i=n} a_i K(x_i, x_j) + b \quad (11)$$

式中: $K(x_i, x_j) = \exp(-|x_i - x_j|^2 / 2\sigma^2)$ —径向基函数。

2.1.2 改进黏菌算法 ISMA

黏菌算法 (Slime Mould Algorithm, SMA) 是一种新型群智能算法, 其模拟了黏菌在寻找食物过程中形态和行为的变化, 具有非常强的全局搜索能力, 其原理及优化步骤可参考文献[16]。

其中, 黏菌的位置更新方式为:

$$\begin{cases} r_{\text{and}}(u - l) + l, r_{\text{and}} < z \\ X(t) + c(WX_A(t) - X_B(t)), r_{\text{and}} \geq z \text{ 且 } r < p \\ cX(t), r_{\text{and}} \geq z \text{ 且 } r > p \end{cases} \quad (12)$$

式中: r_{and}, r — $[0, 1]$ 间的随机数; u 和 l —优化参数的上下限; c — $[-a, a]$ 之间的随机数; c —从 1 递减到 0 的参数; z 取 0.03; W —权重系数; p —决定黏菌位置更新方式的参数; $X_A(t), X_B(t)$ —当代黏菌中的两个随机个体。

SMA 虽然具有较强的全局搜索能力, 但存在初始种群质量低、探索和开发过程难以平衡、后期迭代过程中的震荡作用较弱以及易陷入局部最优等问题。为了改善 SMA 的缺陷, 提高优化效果, 提出改进黏菌算法:

(1) 引入 Logistic 混沌反向学习初始化种群。由于 Logistic 映射具有随机性、规律性、不重复的遍历性的特点, 在求解函数优化问题时这些优点能够

使算法容易跳脱局部最优,从而维持种群多样性,同时保持全局搜索的能力。文献[17]表明,通过反向学习得到的新解,有50%的概率优于当前解。故在Logistic映射的基础上引入反向学习,产生黏菌群落。其过程为:

首先,根据公式(13)生成包含 N 个数的序列 x ,根据式(14)得到对应的黏菌种群。

$$x(t+1) = x(t)(1-x(t)) \quad (13)$$

$$X(t+1) = (x(t+1))(u-l) + l \quad (14)$$

式中: $x(t)$ —第 t 个混沌数; t —迭代次数; $X(t+1)$ — $x(t)$ 对应的黏菌个体; $x \in (0,1)$,且 $x(0)$ 不能为0.25,0.5和0.75。

然后,将序列 x 中的每个混沌数根据式(15)和式(16)生成反向混沌序列 x' 和对应的黏菌种群。

$$x'_x(t) = x_{\max} + x_{\min} - x(t) \quad (15)$$

$$X'_x(t+1) = (x'_x(t+1))(u-l) + l \quad (16)$$

式中: x_{\max} 和 x_{\min} —序列 x 中的最大值和最小值。

(2) 为了解决后期出现的震荡作用较弱以及易陷入局部最优的问题,引入二次插值方法,其原理如下:

假设 X_1 和 X_2 是目标种群中的两个随机个体, $X_1 = (a_1, a_2, a_3, \dots, a_n), X_2 = (b_1, b_2, b_3, \dots, b_n)$,当当前全局最优个体为 $X_z = (c_1, c_2, c_3, \dots, c_n), X_1, X_2, X_z$ 的适应度值分别为 F_1, F_2, F_z ,根据公式(17)更新位置形成新个体 $X = (d_1, d_2, d_3, \dots, d_n)$ 。

$$d_q = \frac{(c_q^2 - b_q^2) \times F_1 + (a_q^2 - c_q^2) \times F_2 + (b_q^2 - a_q^2) \times F_z}{2[(c_q - b_q) \times F_1 + (a_q - c_q) \times F_2 + (b_q - a_q) \times F_z]} \quad (17)$$

其中, $q = 1, 2, 3, \dots, n$ 。

通过式(18)把新个体 X 的适应度值 $F_{\bar{x}}$ 与目前全局最优个体 X_z 进行对比,取优作为新的全局最佳个体 X_b ,对比公式为:

$$X_b = \begin{cases} X & F_x < F_z \\ X_z & F_x > F_z \end{cases} \quad (18)$$

通过二次插值产生新解的方法可以有效提高黏菌算法局部探索和跳出局部最优的能力,还可以起到增加黏菌种群多样性的作用。

2.1.3 ISMA-WLSSVM 模型的搭建

ISMA算法保留了SMA全局搜索能力较强的优点,解决了SMA本身容易陷入局部最优和种群产生

伪随机的问题,改善了算法的寻优性能。因此,引入ISMA算法对WLSSVM模型的两个参数进行优化,搭建光伏发电功率回归预测模型,搭建过程如图2所示。

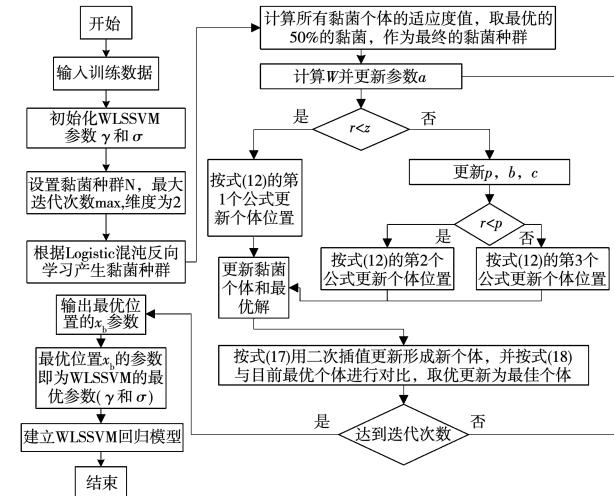


图2 ISMA 优化 WLSSVM 参数流程图

Fig. 2 Flow chart of WLSSVM parameters optimized by ISMA

具体步骤如下:

(1) 设置黏菌种群数量、最大迭代次数、需要优化参数的维度(本文维度为2)。

(2) 产生黏菌种群。

(3) 计算 W 并更新参数 a 。

(4) 根据 r 与 z, p 的大小关系选择黏菌个体的更新方式,更新黏菌个体和最优解。

(5) 执行迭代,判断迭代次数是否等于 \max ,若等于则输出最优位置 x_b ,否则转至步骤(3)继续迭代。

将最后得到的最优位置 x_b 作为WLSSVM的最优参数(γ 和 σ),建立WLSSVM回归预测模型。

2.2 ICEEMDAN-DTW 和 ISMA-WLSSVM 预测模型的搭建

基于ICEEMDAN-DTW和ISMA-WLSSVM的光伏发电功率超短期预测模型流程如图3所示。主要预测流程为:

(1) 对历史光伏发电数据进行Pearson相关性分析,确定预测模型的输入气象影响因素。

(2) 将历史光伏发电功率和气象影响因素进行ICEEMDAN分解。

(3) 采用 DTW 来确定每个 IMF 的最佳输入特征向量。

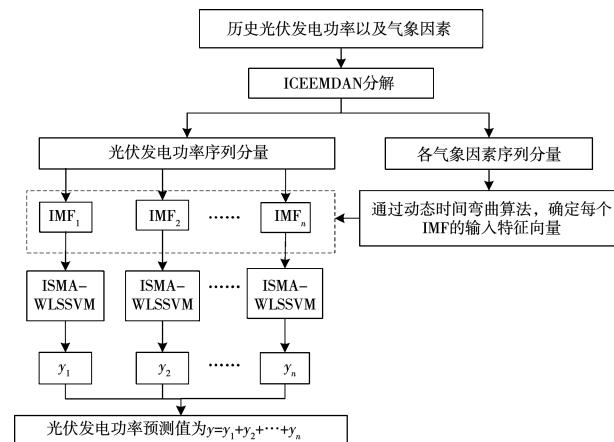


图 3 预测模型流程图

Fig. 3 Flow chart of prediction model

(4) 搭建每个 IMF 的 ISMA-WLSSVM 回归预测模型。

(5) 将每个 IMF 的预测值线性相加记作 y , y 为得到的最终光伏发电功率预测值。

3 实验结果及分析

江苏高邮某光伏电站总装机容量为 100 kW, 2019 年 3 月 ~ 2020 年 6 月, 每日 06:00 ~ 18:00 间隔为 15 min 的实测光伏发电功率、光辐照度、温度以及湿度。利用 Matlab 软件建立基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 预测模型, 对未来 15 min 的光伏发电功率值进行预测。选择 2021 年的 5 月 8 日(晴天)、5 月 10 日(多云)和 5 月 13 日(雨天)作为预测模型对比的样本预测天气。

3.1 评估指标

以均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 及平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 作为评估各预测模型性能的指标。

$$MAE = \frac{1}{N} \sum_{i=1}^{i=N} |y_{true}(i) - y_{pre}(i)| \quad (19)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^{i=N} (y_{true}(i) - y_{pre}(i))^2} \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^{i=N} \left| \frac{y_{true}(i) - y_{pre}(i)}{y_{true}(i)} \right| \times 100\% \quad (21)$$

式中: N —测试样本数; y_{true} —测试样本对应的真实值; y_{pre} —模拟光伏发电功率预测值。

3.2 历史光伏发电功率的分解

对历史光伏发电功率序列进行 ICEEMDAN 分解, 结果如图 4 所示。由图 4 可知, ICEEMDAN 分解实现了对历史光伏发电功率序列各分量的准确分离, 有效降低了光伏发电功率序列的复杂度和预测难度。

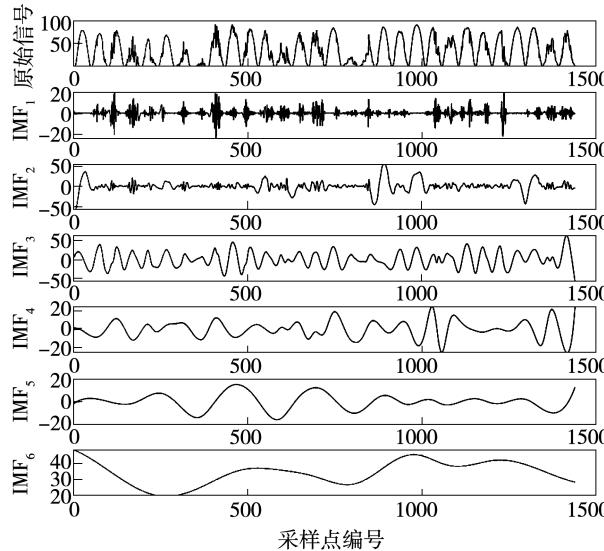


图 4 光伏功率分解结果

Fig. 4 Decomposition results of photovoltaic power

3.3 光伏功率 IMF 的输入特征向量的选取

对气象因素进行 ICEEMDAN 分解, 之后引入 DTW, 计算每个气象因素的 imf 与光伏功率子序列 IMF 的距离 (DTW 值), 如表 1 ~ 表 3 所示。

表 1 光辐照度与功率的距离关系

Tab. 1 Distance relation between light irradiance and PV power

距离	imf ₁	imf ₂	imf ₃	imf ₄	imf ₅	imf ₆
IMF ₁	9.10	9.00	6.87	12.72	16.81	6.46
IMF ₂	10.78	2.06	7.15	6.43	6.66	12.36
IMF ₃	2.06	8.85	1.78	28.64	28.67	1.09
IMF ₄	2.48	9.24	2.56	23.02	29.54	0.98
IMF ₅	15.73	10.63	17.32	0.45	0.30	23.56
IMF ₆	19.20	10.25	0.35	23.93	0.35	0.21

表 2 温度与功率的距离关系

Tab. 2 Distance relation between temperature and PV power

距离	imf_1	imf_2	imf_3	imf_4	imf_5	imf_6
IMF₁	6.12	7.20	8.40	8.50	12.83	12.18
IMF₂	6.34	4.36	2.38	2.43	6.51	6.64
IMF₃	11.02	8.30	7.01	4.89	15.00	13.36
IMF₄	5.03	5.20	3.16	4.25	0.27	0.30
IMF₅	10.92	5.22	2.41	0.86	7.00	6.96
IMF₆	10.27	12.30	21.30	15.63	24.11	23.36

表 3 湿度与功率的距离关系

Tab. 3 Distance relation between humidity and PV power

距离	imf_1	imf_2	imf_3	imf_4	imf_5	imf_6
IMF₁	7.44	11.26	10.85	10.64	10.88	12.22
IMF₂	2.48	5.42	7.95	11.07	12.54	16.76
IMF₃	6.70	10.81	15.00	12.41	10.18	6.93
IMF₄	6.30	4.93	3.38	10.25	12.59	23.82
IMF₅	3.16	6.42	9.50	12.83	11.28	8.41
IMF₆	10.29	18.68	16.32	6.37	4.09	0.29

综合所有实验结果,选取每个气象因素中 DTW 值小于 10 的 imf 作为 IMF 的最佳输入特征向量,光伏功率子序列 IMF 的最佳输入特征向量见表 4。

表 4 光伏功率子序列的最佳输入特征向量

Tab. 4 Optimal input eigenvectors of PV power subsequence

功率	光辐照度	温度	湿度
IMF₁	$\text{imf}_1, \text{imf}_2, \text{imf}_3$	$\text{imf}_1, \text{imf}_2, \text{imf}_3$	imf_1
IMF₂	$\text{imf}_2, \text{imf}_3, \text{imf}_4,$ imf_5	$\text{imf}_1, \text{imf}_2, \text{imf}_3,$ $\text{imf}_4, \text{imf}_5, \text{imf}_6$	$\text{imf}_1, \text{imf}_2, \text{imf}_3$
IMF₃	$\text{imf}_1, \text{imf}_2, \text{imf}_3,$ imf_6	$\text{imf}_2, \text{imf}_3, \text{imf}_4$	$\text{imf}_1, \text{imf}_6$
IMF₄	$\text{imf}_1, \text{imf}_2, \text{imf}_3,$ imf_6	$\text{imf}_2, \text{imf}_3, \text{imf}_4,$ $\text{imf}_5, \text{imf}_6$	$\text{imf}_1, \text{imf}_2, \text{imf}_3$
IMF₅	$\text{imf}_4, \text{imf}_5$	$\text{imf}_1, \text{imf}_2, \text{imf}_3,$ $\text{imf}_4, \text{imf}_5, \text{imf}_6$	imf_6
IMF₆	$\text{imf}_3, \text{imf}_5, \text{imf}_6$		$\text{imf}_4, \text{imf}_5, \text{imf}_6$

3.4 ISMA 的优化性能分析

为了检验 ISMA 算法的性能,将 ISMA 同时与粒子群算法 (Particle Swarm Optimization, PSO)、SMA 算法的适应度曲线进行对比,如图 5 所示。可以看

到,PSO 到第 36 次才寻到最优值,表明 PSO 寻优能力一般;而 SMA 收敛速度全程比 PSO 快,且在第 22 次寻到最优值,但寻优效果仅比 PSO 略好;ISMA 在第 16 次时就寻到最优适应度值,且远比 PSO 与 SMA 的最优值小,证明 ISMA 有效缓解了原 SMA 种群产生伪随机的问题,同时提高了算法跳出局部极值的能力和寻优精度。

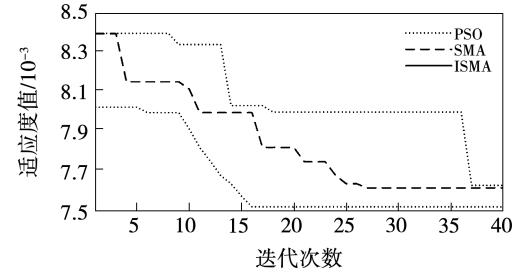


图 5 3 种优化算法适应度曲线

Fig. 5 Fitness curves of three optimization algorithms

分别搭建 PSO-WLSSVM, SMA-WLSSVM 和 ISMA-WLSSVM 预测模型对同一天进行预测,预测结果如表 5 所示。由表 5 可知,ISMA 寻到的最优参数比 PSO 和 SMA 的更精确。

表 5 不同优化算法下各预测模型的误差评价指标值

Tab. 5 Error evaluation index values of each prediction model by different optimization algorithms

预测方法	RMSE	MAE	MAPE
PSO-WLSSVM	4.173 1	3.647 0	0.163 8
SMA-WLSSVM	3.950 1	3.439 6	0.152 7
ISMA-WLSSVM	3.494 6	2.873 7	0.136 8

3.5 ICEEMDAN-DTW 和 ISMA-WLSSVM 预测模型有效性验证

为了验证所提预测模型的性能,搭建了 WLSSVM(模型 1)、EOSSA-ELM^[18](模型 2)、ISMA-LSSVM(模型 3)、ISMA-WLSSVM(模型 4)、ICEEMDAN(分解功率序列)-ISMA-WLSSVM(模型 5)、ICEEMDAN-DTW 和 SMA-WLSSVM(模型 6)、ICEEMDAN(分解气象因素序列和功率序列)-ISMA-WLSSVM(模型 7)以及 ICEEMDAN-DTW 和 ISMA-WLSSVM(本模型),同时对 5 月 8 日(晴天)、5 月 10 日(多云)及 5 月 13 日(雨天)这 3 天的光伏发电功率进行预测,预测曲线对比见图 6,预测精度见表 6。

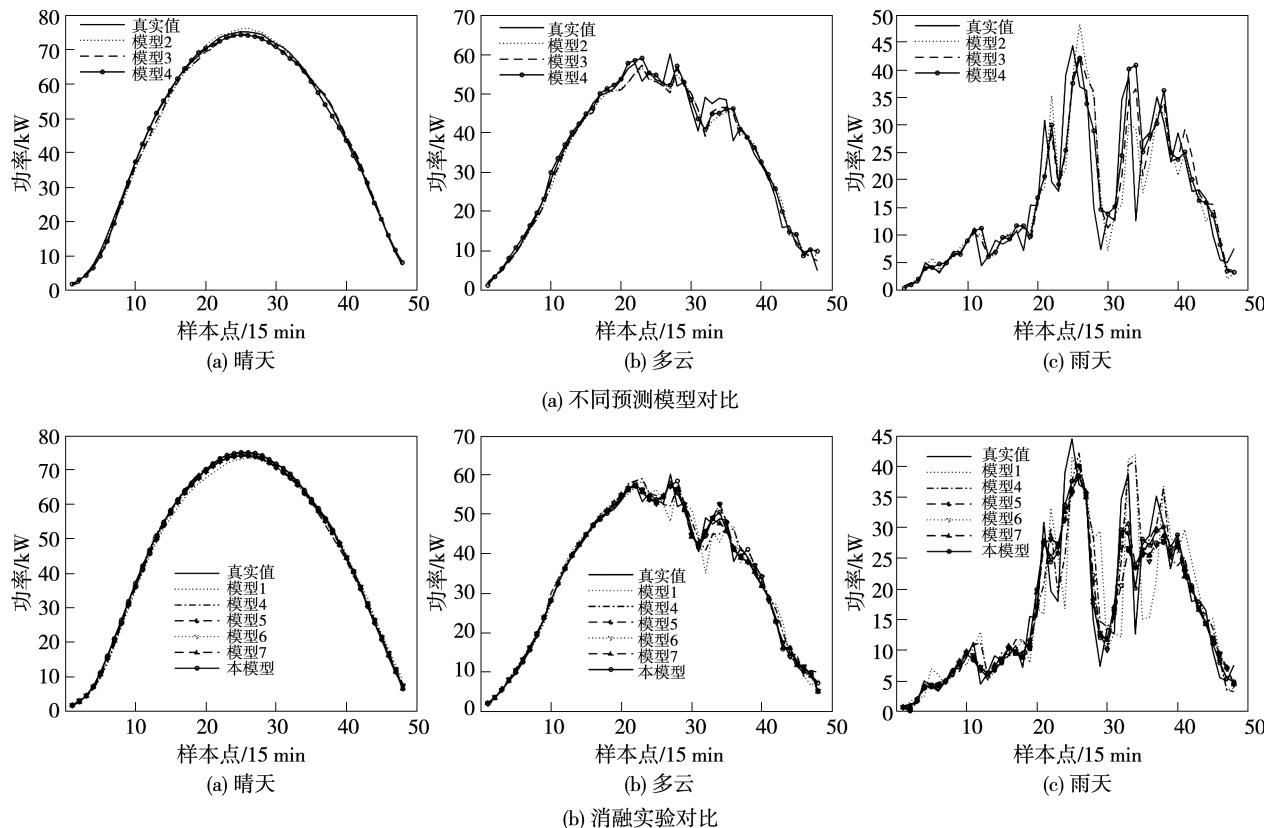


图 6 不同天气类型多个方法预测曲线

Fig. 6 Prediction curves of multiple methods of different weather types

表 6 预测误差

Tab. 6 Prediction errors

天气类型	预测模型	RMSE	MAE	MAPE
晴天	模型 1	1.700 4	1.499 8	0.052 9
	模型 2	1.181 2	0.898 2	0.032 4
	模型 3	1.102 8	0.942 4	0.035 7
	模型 4	1.005 4	0.817 0	0.037 3
	模型 5	0.852 6	0.779 1	0.025 7
	模型 6	0.791 7	0.721 9	0.023 4
	模型 7	0.637 3	0.593 9	0.024 8
多云	本模型	0.503 4	0.444 9	0.014 6
	模型 1	3.842 7	2.411 9	0.089 9
	模型 2	3.136 2	2.177 2	0.085 3
	模型 3	3.010 7	1.981 2	0.068 9
	模型 4	2.809 3	1.833 6	0.084 9
	模型 5	1.851 4	1.312 7	0.051 8
	模型 6	1.673 8	1.226 7	0.042 4
雨天	模型 7	1.509 3	1.057 9	0.032 3
	本模型	1.332 4	0.911 7	0.026 4
	模型 1	9.048 9	5.892 2	0.453 7
	模型 2	7.187 2	4.790 9	0.329 9
	模型 3	6.560 8	4.046 1	0.280 4
	模型 4	6.269 3	3.757 6	0.298 5
	模型 5	4.737 9	3.308 0	0.247 2
雨天	模型 6	4.403 1	3.171 6	0.241 4
	模型 7	3.797 1	2.823 9	0.221 2
	本模型	3.414 8	2.502 3	0.191 4

从图 6(a)可知,相对于模型 2,3 来说,在 3 种天气类型下,预测模型 4 的预测值及变化趋势更接近于实际功率值,表明 ISMA-WLSSVM 模型对于光伏发电功率的预测性能更好,也表明 WLSSVM 模型在光伏发电功率预测领域具有更好的建模效果。从图 6(b)可知,(1) 模型 4 相对于模型 1 来说,3 种误差指标明显降低,说明使用优化算法来选取参数,可以更加深入地挖掘模型的预测性能,从而提高整体的预测精度,表明了优化算法在 WLSSVM 参数优化上具有明显的优势;(2) 模型 5,7 以及本模型对历史光伏发电功率序列进行分解,相比模型 4 精度得到大幅度提升,证明对光伏发电功率序列进行分解,可以有效挖掘信号的局部特征信息,大幅改善模型的预测性能;(3) 模型 7 相对于模型 5, RMSE 分别降低了 25.3%, 18.5% 和 19.9%, 表明对气象因素和功率都进行 ICEEMDAN 分解,改善了分解后的光伏发电功率子序列与气象因素的相关程度;(4) 都进行 ICEEMDAN 分解的模型 6 与本模型,在不同天

气类型下本模型的 3 个误差指标都最小,再次验证对 SMA 的改进能提高 SMA 的优化性能;(5) 本模型的预测精度相比模型 7, RMSE 分别降低了 21.0%, 11.70% 和 10.1%, 预测精度得到提升, 证明引入 DTW 来确定不同光伏发电功率子序列的最佳输入特征向量对提高光伏发电功率预测精度的作用。

4 结 论

提出一种基于 ICEEMDAN-DTW 和 ISMA-WLSSVM 的超短期光伏发电功率组合预测模型, 并在实际电站数据的基础上进行了仿真实验验证, 结果表明:

(1) 针对随机性强的光伏发电功率以及气象因素进行 ICEEMDAN 分解, 并通过 DTW 算法确定每个光伏功率子序列的最佳输入特征向量, 本预测模型的 RMSE 在晴天、多云和雨天分别为 0.5034, 1.3324 和 3.4148, 相比其他预测模型均最小, 表明本模型的预测精度最高, 也证明了该方法有效增强了光伏发电功率子序列与其输入特征向量之间的相关性。

(2) 通过对 LSSVM 的每个误差序列分配权重得到 WLSSVM, 它们在相同条件下, WLSSVM 比 LSSVM 的 RMSE 在 3 种不同天气下分别降低了 8.8%, 6.7% 和 4.4%, 证明了 WLSSVM 在光伏发电功率预测领域具有更好的建模效果。

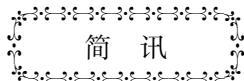
(3) 针对黏菌算法目前存在的缺陷, 在 SMA 的基础上, 优化了黏菌的种群产生方式以及迭代过程中最优个体的更新方式, 得到改进黏菌算法 ISMA 并应用到 WLSSVM 的参数优化中, 与原 SMA 一同预测多种天气类型的光伏发电功率, 采用 ISMA 的预测模型比采用 SMA 的预测模型的 RMSE 分别降低了 36.4%, 20.4% 和 22.4%, 有力证明了其在减少迭代次数的同时寻优效果也优于 SMA, 能更加充分发挥 WLSSVM 模型的预测性能。

参考文献:

- [1] 文劲宇,周博,魏利屾.中国未来电力系统储电网初探[J].电力系统保护与控制,2022,50(7):1-10.
WEN Jin-yu,ZHOU Bo,WEI Li-shen.Preliminary study on an energy storage grid for future power system in China[J].Power System Protection and Control,2022,50(7):1-10.
- [2] 李正明,梁彩霞,王满商.基于 PSO-DBN 神经网络的光伏短期发电出力预测 [J]. 电力系统保护与控制, 2020, 48 (8): 149 - 154.
LI Zheng-ming, LIANG Cai-xia, WANG Man-shang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48 (8): 149 - 154.
- [3] THEVENARD D, PELLAND S. Estimating the uncertainty in long-term photovoltaic yield predictions [J]. Solar Energy, 2013, 91: 432 - 445.
- [4] MA T, YANG H, LU L. Solar photovoltaic system modeling and performance prediction [J]. Renewable and Sustainable Energy Reviews, 2014, 36: 304 - 315.
- [5] CHAKRABORTY S, WEISS M D, SIMOES M G. Distributed intelligent energy management system for a single-phase high-frequency AC microgrid [J]. IEEE Transactions on Industrial Electronics, 2007, 54(1):97 - 109.
- [6] 李光华. 基于皮尔逊理论与径向基函数神经网络的光伏功率预测 [J]. 电气技术与经济, 2022(1):14 - 16.
LI Guang-hua. Photovoltaic power prediction based on Pearson theory and neural networks of radial basis functions[J]. Electrical Equipment and Economy, 2022(1):14 - 16.
- [7] 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.
- [8] 张雨金,杨凌帆,葛双治,等. 基于 Kmeans-SVM 的短期光伏发电功率预测 [J]. 电力系统保护与控制, 2018, 46 (21): 118 - 124.
ZHANG Yu-jin, YANG Ling-fan, GE Shuang-zhi, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine [J]. Power System Protection and Control, 2018, 46(21):118 - 124.
- [9] 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.
YANG Mao, YANG Yu. Short-term photovoltaic output power prediction based on wavelet packet and LSSVM[J]. Renewable Energy Resources, 2019, 37(11):1595 - 1602.
- [10] 阳霜,罗滇生,何洪英,等. 基于 EMD-LSSVM 的光伏发电系统功率预测方法研究 [J]. 太阳能学报, 2016, 37 (6): 1387 - 1395.

- YANG Shuang, LUO Dian-sheng, HE Hong-ying, et al. Output power forecast of PV power system based on EMD-LSSVM model [J]. Acta Energiae Solaris Sinica, 2016, 37(6): 1387–1395.
- [11] 武小梅, 张琦, 田明正. 基于 VMD-SE 和优化支持向量机的光伏发电预测方法 [J]. 电力科学与工程, 2017, 33(9): 29–36.
WU Xiao-mei, ZHANG Qi, TIAN Ming-zheng. Photovoltaic prediction method based on VMD-SE and optimized support vector machine [J]. Electric Power Science and Engineering, 2017, 33(9): 29–36.
- [12] 李斌, 张一凡, 颜世烨, 等. 基于改进极限学习机 ELM 的光伏发电预测方法研究 [J]. 热能动力工程, 2022, 37(10): 207–214.
LI Bin, ZHANG Yi-fan, YAN Shi-ye, et al. Research on photovoltaic power generation prediction method based on improved extreme learning machine (ELM) [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(10): 207–214.
- [13] 袁建华, 谢斌斌, 何宝林, 等. 基于 DTW-VMD-PSO-BP 的光伏发电功率短期预测方法 [J]. 太阳能学报, 2022, 43(8): 58–66.
YUAN Jian-hua, XIE Bin-bin, HE Bao-lin, et al. Short term forecasting method of photovoltaic output based on DTW-VMD-PSO-BP [J]. Acta Energiae Solaris Sinica, 2022, 43(8): 58–66.
- [14] 张涛, 朱瑞金, 扎西顿珠, 等. 基于改进骨干差分进化算法优化 LSSVM 的短期光伏发电功率预测 [J]. 热力发电, 2021, 50(5): 102–107.
ZHANG Tao, ZHU Rui-jin, ZHAXI Dun-zhu, et al. Short-term photovoltaic power prediction based on IBBDE-LSSVM [J]. Thermal Power Generation, 2021, 50(5): 102–107.
- [15] 张新生, 张莹莹. 基于 KPCA-ALO-WLSSVM 的埋地管道外腐蚀速率预测 [J]. 安全与环境学报, 2022, 22(4): 1804–1812.
ZHANG Xin-sheng, ZHANG Ying-ying. Prediction of external corrosion rate of buried pipeline based on KPCA-ALO-WLSSVM [J]. Journal of Safety and Environment, 2022, 22(4): 1804–1812.
- [16] LI S M, CHEN H L, WANG M J, et al. Slime mould algorithm: a new method for stochastic optimization [J]. Future Generation Computer Systems, 2020, 111: 300–323.
- [17] RAHNAMAYAN S, TIZHOOSH H R, SALAMA M M A. Opposition based differential evolutions [J]. IEEE Transactions on Industrial Electronics, 2008, 55(12): 64–79.
- [18] 陈骏豪, 张娜, 刘广忱, 等. 基于 EOSSA-ELM 的光伏短期输出功率预测 [J]. 可再生能源, 2022, 40(7): 890–898.
CHEN Jun-hao, ZHANG Na, LIU Guang-cheng, et al. Photovoltaic short-term output power forecasting based on EOSSA-ELM [J]. Renewable Energy Resources, 2022, 40(7): 890–898.

(丛敏编辑)



三菱重工将为日本政府加快反应堆设计工作

据官网报道, 日本政府计划于 21 世纪 40 年代投入运行示范快中子反应堆(快堆), 三菱重工(MHI)被选作负责快堆概念设计的核心企业。

三菱重工将与三菱 FBR 系统公司合作, 监督钠冷快堆的概念设计和研发。三菱 FBR 系统公司是三菱重工集团的工程公司, 负责快堆的开发和设计。该项概念设计工作计划将于 2024 财政年度开始启动。

该计划已于 2022 年底更新, 做出了两项决定: 第一, 选择一个钠冷快堆作为示范反应堆概念设计的目标, 计划在 2024 财政年度开始启动; 第二, 选择一家制造商作为负责快堆设计和研发的核心公司。

三菱重工还参与了一个美日合作项目, 旨在加快反应堆开发速度, 并建立内部钠测试设施。三菱重工表示, 它将继续改进其技术及开发所需的人力资源, 以支持这一重要举措。

(孙嘉忆摘译自 www.powerengineeringint.com)