

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

张 涛, 朱瑞金, 扎西顿珠
(西藏农牧学院电气工程学院, 西藏 林芝 860000)

[摘 要] 准确预测光伏发电功率对于保障电力系统安全稳定和经济运行具有重要意义。提出一种基于改进骨干差分进化算法 (IBBDE) 优化最小二乘支持向量机 (LSSVM) 的光伏发电功率预测模型。IBBDE 算法采用广义反向学习初始化种群和自适应调整交叉概率对骨干差分进化算法进行改进以提升算法的全局寻优能力, 利用 IBBDE 算法优化 LSSVM 预测模型的正规化参数和核参数来提高模型的预测精度。采用西藏某光伏电站发电功率进行预测仿真, 结果表明: 晴天天气下, IBBDE-LSSVM 模型预测结果平均绝对误差和均方根误差分别为 5.39% 和 3.98%; 雨天天气下, IBBDE-LSSVM 模型预测结果平均绝对误差和均方根误差分别为 10.69% 和 7.86%, 预测效果较好。

[关 键 词] 光伏发电; 功率预测; 最小二乘支持向量机; 骨干差分进化; 广义反向学习; 自适应
[中图分类号] TM615 **[文献标识码]** A **[DOI 编号]** 10.19666/j.rlfid.202007213

[引用本文格式] 张涛, 朱瑞金, 扎西顿珠. 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 Ruijin, ZHAXI Dunzhu. Short-term photovoltaic power prediction based on IBBDE-LSSVM[J]. Thermal Power Generation, 2021, 50(5): 102-107.

Short-term photovoltaic power prediction based on IBBDE-LSSVM

ZHANG Tao, ZHU Ruijin, ZHAXI Dunzhu

(School of Electrical Engineering, Tibet Agriculture & Animal Husbandry University, Nyingchi 860000, China)

Abstract: Accurate evaluation of photovoltaic power is of great significance to ensure safety and stability and economic operation of power systems. In this paper, a short-term photovoltaic power prediction model based on least square support vector machine (LSSVM) optimized by improved bare-bones differential evolution algorithm (IBBDE) is proposed. Initialization of population using generalized opposition based learning and self-adaption of crossover factor are introduced to enhance the global convergence of algorithm. The IBBDE algorithm is adopted to optimize the regularization parameters and kernel parameters of LSSVM, thus to improve the short-term photovoltaic power forecasting accuracy. Simulations are performed on a realistic photovoltaic power station in Tibet, and the results shows that, the proposed method has high prediction accuracy. In sunny weather, the mean absolute prediction error (MAPE) and root-mean-square error (RMSE) are 5.39% and 3.98%, respectively. In rainy weather, the MAPE and RMSE are 10.69% and 7.86%, respectively.

Key words: photovoltaic generation, power prediction, LSSVM, bare-bones differential evolution algorithm, generalized opposition based learning, self-adaption

光伏发电具有绿色清洁、可再生、灵活高效等特点, 近年来被世界各国重视并利用。截至 2019 年 12 月底, 我国共有 9 个省级电网的光伏发电装机容量

量超过 10 GW, 西藏地区光伏发电装机容量接近总装机的 40%。光伏发电功率具有很强的间歇性和波动性, 高比例光伏接入后将对电网调度运行控制带

修回日期: 2020-09-08

基金项目: 西藏自治区自然科学基金(XZ2019ZRG-52(Z))

Supported by: Natural Science Foundation of Tibet Autonomous Region(XZ2019ZRG-52(Z))

第一作者简介: 张涛(1989), 男, 硕士, 讲师, 主要研究方向为新能源发电预测技术, 1360462946@qq.com。

通信作者简介: 朱瑞金(1986), 男, 硕士, 副教授, 主要研究方向为智能电网技术, zhuruijin@xza.edu.cn。

©1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

来较大冲击。因此，准确预测光伏电站发电功率对于保障电力系统安全、稳定、经济运行和提高光伏电站运营效率具有重要的意义^[1-3]。

长期以来，国内外研究人员先后提出了多种有效的光伏发电功率预测方法，这些方法总体可分为 2 类：1) 统计分析法，该方法通过对光伏电站发电功率历史数据的曲线拟合以及参数估计等对未来光伏发电功率进行预测，常见的统计分析法有回归分析法^[4]、时间序列法^[5]、灰色预测法^[6]和时空关联法^[7]等；2) 机器学习法，该方法采用人工智能技术，通过大量样本训练，建立光伏电站发电功率与影响因素间的非线性映射关系，从而实现未来发电功率预测，常见的机器学习法有神经网络^[8]、深度信念网络^[9]、极限学习机^[10]和支持向量机 (SVM)^[11-12]等。其中，SVM 预测模型基于风险最小化原理构造决策函数，能有效解决小样本、高维数的非线性问题，在相关预测问题中得到了广泛应用。

最小二乘支持向量机 (LSSVM) 模型是标准 SVM 的扩展，LSSVM 以二次损失函数为经验风险，并以等式约束代替不等式约束，将模型的训练转化为线性方程组的求解，降低了计算复杂性^[13]。然而，LSSVM 模型的预测精度和泛化能力受正则化参数和核函数影响较大，通常根据经验采用人工比对法确定 LSSVM 参数，这种方法效率低，盲目性大。为此，研究人员分别采用遗传算法^[14]、粒子群优化算法^[15]、果蝇优化算法^[16]和差分进化 (differential evolution, DE) 算法^[17]等计算智能技术来优化 LSSVM 预测模型参数，均取得了比较理想的预测效果。

骨干差分进化 (bare-bones differential evolution, BBDE) 算法是 Wang 等人^[18]在标准 DE 算法基础上提出的一种新型智能优化技术，具有易操作、控制参数少、寻优能力强等优点。为获得更理想的短期光伏发电功率预测结果，本文提出一种基于改进 BBDE 算法 (improved BBDE, IBBDE) 优化 LSSVM 的短期光伏发电功率预测方法。相较于 BBDE 算法，IBBDE 算法的改进主要体现在 2 个方面：1) 采用基于广义反向学习的种群初始化策略；2) 自适应调整交叉概率。利用本文所提预测方法对西藏林芝地区某光伏电站在晴天和雨天天气下进行功率预测，并将预测结果与基于 BBDE 算法和 DE 算法优化 LSSVM 参数的预测模型进行比较。

1 最小二乘支持向量机 (LSSVM) 模型

设 $s = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \in \mathbf{R}^n \times \mathbf{R}$ 为训练样本集， l 为训练样本个数，在高维特征空间构造最优线性回归函数：

$$f(x) = \omega^T \varphi(x) + b \quad (1)$$

式中： $\varphi(x)$ 为从输入空间到高维特征空间的非线性变换， ω 为特征空间权向量， b 为偏差量。

根据结构风险最小化原则，LSSVM 模型的目标函数可表示为

$$\min \frac{1}{2} \omega^T \omega + \frac{\lambda}{2} \sum_{i=1}^l e_i^2 \quad (2)$$

式中： λ 为正则化参数， e 为训练集预测误差向量。

约束条件为

$$y_i = \omega^T \varphi(x_i) + b + e_i \quad (3)$$

引入拉格朗日函数将上述优化问题变换到对偶空间，即

$$L = \frac{1}{2} \omega^T \omega + \frac{\lambda}{2} \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \alpha_i [\omega^T \varphi(x_i) + b + e_i - y_i] \quad (4)$$

式中 α_i 为拉格朗日乘子。根据 KKT 条件，可得

$$\begin{cases} \omega = \sum_{i=1}^l \alpha_i \varphi(x_i) \\ \sum_{i=1}^l \alpha_i = 0 \\ \alpha_i = \lambda e_i \\ \omega^T \varphi(x_i) + b + e_i - y_i = 0 \end{cases} \quad (5)$$

消去 ω 和 e_i ，式(5)可转化为

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{c} & \dots & K(x_1, x_l) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & K(x_l, x_1) & \dots & K(x_l, x_l) + \frac{1}{c} \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (6)$$

式中 $K(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$ 为核函数。核函数一般选取径向基函数：

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / (2\sigma^2)) \quad (7)$$

式中 σ 为核参数。

最后，得到 LSSVM 预测模型为

$$y(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (8)$$

由此可见，LSSVM 的预测效果主要取决于正则化参数 λ 和核参数 σ 的取值。

2 改进的骨干差分进化 (IBBDE) 算法

2.1 标准 DE 算法

差分进化算法 (DE) 是 Store 在 1995 年提出的一种基于种群进化的智能优化算法。假设 T 为进化代数, N_P 为种群规模, D 为解空间维度, 种群在第 T 代的个体 $x_{i,T}=(x_{i1,T}, x_{i2,T}, \dots, x_{iD,T})$, 标准 DE 算法的步骤如下。

1) 初始化种群 标准 DE 算法一般采用随机初始化种群策略, 其表达式为

$$x_{ij,0} = x_{j,\min} + (x_{j,\max} - x_{j,\min})r_{ij} \quad (9)$$

式中, $x_{j,\max}$ 、 $x_{j,\min}$ 分别为第 j 个控制变量的上、下限, r_{ij} 为在 $[0,1]$ 区间的随机数。

2) 变异操作 变异操作是 DE 算法的核心内容, 常用的变异策略为

$$v_{i,T} = x_{i,T} + F(x_{r1,T} - x_{r2,T}) \quad (10)$$

式中: $v_{i,T}$ 为第 i 个变异个体, $x_{i,T}$ 为第 i 个父代个体, $x_{r1,T}$ 和 $x_{r2,T}$ 分别为父代中 2 个互不相同且不同于 $x_{i,T}$ 的个体, F 为变异率。

3) 交叉操作 交叉操作能增加种群多样性, 其表达式为

$$\bar{x}_{ij,T+1} = \begin{cases} v_{ij,T}, & \text{if } r_j \leq C_r \text{ or } j = j_{\text{rand}} \\ x_{ij,T}, & \text{otherwise} \end{cases} \quad (11)$$

式中: $\bar{x}_{ij,T+1}$ 为试验个体, C_r 为交叉率, r_j 为在 $[0,1]$ 区间的随机数, $j_{\text{rand}} \in [1,2,\dots,D]$ 为随机选择的 1 个整数。

4) 选择操作 选择操作通过比较父代个体和子代个体的目标函数值来选择更优的个体, 其表达式为

$$x_{i,T+1} = \begin{cases} \bar{x}_{i,T+1}, & \text{if } f(\bar{x}_{i,T+1}) \leq f(x_{i,T}) \\ x_{i,T}, & \text{otherwise} \end{cases} \quad (12)$$

式中 $f(\cdot)$ 为目标函数值。

2.2 BBDE 算法

标准 DE 算法对控制参数 F 取值比较敏感, 由式(10)看出, F 控制着扰动量的大小, F 取较大值有利于种群进行全局搜索, F 取较小值则有利于局部搜索。不同的控制参数 F 适用于不同的问题, 且其对求解性能影响很大, 一般只能通过大量的试探工作来获取合理的控制参数。针对此问题, 文献[18]借鉴骨干粒子群算法的思想, 提出了一种基于高斯变异的骨干差分进化算法 (BBDE), 其变异策略为

$$v_{i,T} = N\left(\frac{x_{i,T} + g_{\text{best},T}}{2}, |x_{i,T} - g_{\text{best},T}|\right) \quad (13)$$

式中, $g_{\text{best},T}$ 为第 T 代全局最优解, $N(\cdot)$ 为高斯分布函数。由式(13)可以看出, BBDE 算法通过追踪当前种群中的全局最优解 g_{best} 来实现高斯变异, 从而推动种群进化, 避免了对控制参数 F 的反复试探。

2.3 IBBDE 算法

为进一步提升 BBDE 算法的寻优性能, 本文引入基于广义反向学习的种群初始化策略和自适应调整交叉概率策略对 BBDE 算法进行改进。

2.3.1 广义反向学习初始化种群

定义 1 假设 $z \in [a, b]$ 为一维空间中的点, 则 z 的广义反向点 \tilde{z} 定义为

$$\tilde{z} = k(a+b) - z \quad (14)$$

式中 k 为 $[0,1]$ 区间的随机数。

定义 2 假设 $P=(z_1, z_2, \dots, z_D)$ 为一个 D 维空间的点, 且 $z_i \in [a_i, b_i]$, 则 P 的广义反向点 $\tilde{P}=(\tilde{z}_1, \tilde{z}_2, \dots, \tilde{z}_D)$ 定义为

$$\tilde{z}_i = k(a_i + b_i) - z_i \quad (15)$$

式中若 \tilde{z}_i 超过限值, 则在限值范围内随机生成 \tilde{z}_i 。

广义反向学习的基本思想是同时评价原始解及其广义反向解, 选择较优的解作为下一代个体。研究表明, 采用广义反向学习策略能有效提高种群的多样性^[19]。广义反向学习初始化种群步骤如下:

1) 按照式(9)生成临时初始种群 \bar{x}_0 ;

2) 按照式(15)生成 $\bar{x}_{i,0}$ 的广义反向解 $\tilde{x}_{i,0}$;

3) 评价 $\tilde{x}_{i,0}$ 及广义反向解 $\tilde{x}_{i,0}$, 对于最小化目标函数的优化问题, 若 $f(\tilde{x}_{i,0}) < f(\bar{x}_{i,0})$, 则选择 $\tilde{x}_{i,0}$ 作为初始种群中的个体, 反之, 选择 $\bar{x}_{i,0}$ 作为初始种群中的个体。

2.3.2 自适应调整交叉概率

BBDE 算法虽然解决了变异率 F 的选取问题, 但还面临着交叉概率 C_r 的选择。本文采用自适应调整 C_r 的策略, 对适应度好的个体, C_r 取较小值, 避免对该个体造成破坏; 对适应度较差的个体, C_r 取较大值, 提高产生更优个体的几率^[20]。每个个体交叉概率 C_{ri} 的计算公式为

$$C_{ri} = \begin{cases} C_{r,\min} + (C_{r,\max} - C_{r,\min}) \frac{f_i - f_{\min}}{f_{\max} - f_{\min}}, & f_i \geq f_{\text{ave}} \\ C_{r,\min}, & f_i < f_{\text{ave}} \end{cases} \quad (16)$$

式中: $C_{r,\max}$ 、 $C_{r,\min}$ 分别为交叉概率的上、下限, f_i 、 f_{ave} 、 f_{\max} 、 f_{\min} 分别为第 i 个个体的适应度、种群适应度平均值、最差个体适应度和最优个体适应度。

由式(16)可以看出：如果个体适应度大于种群平均适应度，说明该个体较差，应增加交叉概率；如果个体适应度小于种群平均适应度，说明该个体较优，应减小交叉概率，增加该个体进入下一代的几率。

3 基于 IBBDE-LSSVM 的光伏发电功率预测

研究表明，太阳辐射强度、大气温度和相对湿度是影响光伏发电的主要因素^[12]。因此，本文将上述 3 个因素作为预测模型的输入，光伏发电功率作为模型的输出。

基于 IBBDE-LSSVM 的光伏发电功率预测流程如图 1 所示，其主要步骤如下。

1) 对输入数据进行归一化处理，划分训练集和测试集,选择与预测日的天气类型（晴天、阴天、雨天）相近的 10 天的数据作为训练样本集。

2) 设置 IBBDE 算法参数，并采用广义反向策略初始化 LSSVM 模型参数。

3) 采用 IBBDE 算法对 LSSVM 模型参数进行优化，其中适应度评价函数 f_e 为

$$f_e = \sqrt{\sum_{i=1}^l (P_i - \bar{P}_i)^2 / l} \quad (17)$$

式中： l 为训练样本数， P_i 为第 i 个样本点的实际值， \bar{P} 为第 i 个样本点的预测值。

4) 利用优化后的 LSSVM 模型进行光伏发电功率预测。

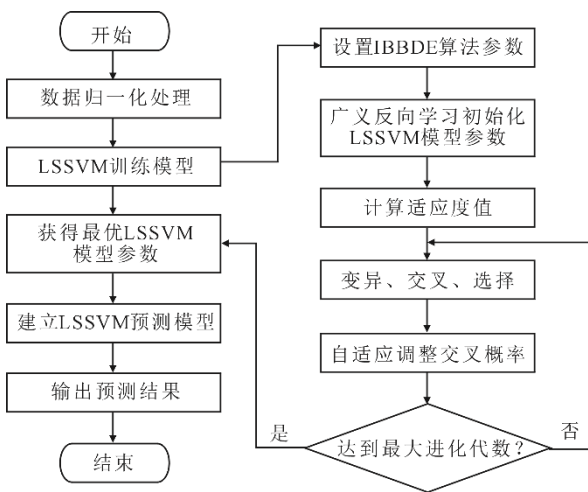


图 1 光伏发电功率预测流程
Fig.1 Flowchart of photovoltaic power prediction

4 算例分析

4.1 算例介绍

本文选取西藏林芝地区某光伏电站为研究对象，预测晴天和雨天天气下的光伏发电功率。数据采样时间为 2019 年 11 月 8:30—20:00，采样间隔为 15 min。选取预测日为 11 月 16 日（晴天）和 11 月 17 日（雨天），训练样本按照预测日的类型选取相近的 10 天。选择平均绝对误差百分比 (σ_{MAPE}) 和均方根误差 (σ_{RMSE}) 来评价预测结果。

$$\sigma_{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|S_i - \bar{S}_i|}{\bar{S}_i} \quad (18)$$

$$\sigma_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{S_i - \bar{S}_i}{\bar{S}_i} \right)^2} \quad (19)$$

式中： N 为预测点个数， S_i 为第 i 个点的预测值， \bar{S}_i 为第 i 个点的实际值。

4.2 预测结果分析

分别采用 IBBDE-LSSVM、BBDE-LSSVM 和 DE-LSSVM 进行光伏发电功率预测，3 种优化算法的参数设置见表 1，3 种预测模型的光伏发电预测曲线如图 2、图 3 所示。由图 2 和图 3 可见，晴天天气下，光伏发电功率波动较小，3 种预测模型的光伏发电功率预测轨迹大致相同，本文 IBBDE-LSSVM 模型的预测功率曲线和实际输出功率曲线更贴近。

表 1 不同光伏发电功率预测算法参数设置
Tab.1 The parameters setting for different PV Power prediction algorithms

算法	参数设置
DE-LSSVM	$N_P=20, F=0.9, C_r=0.5, T=100$
BBDE-LSSVM	$N_P=20, C_r=0.5, T=100$
IBBDE-LSSVM	$N_P=20, C_{r,max}=0.9, C_{r,min}=0.1, T=100$

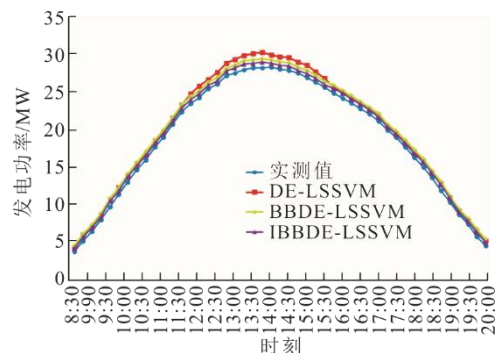


图 2 晴天天气光伏发电功率预测结果
Fig.2 The prediction results of photovoltaic power generation in sunny weather

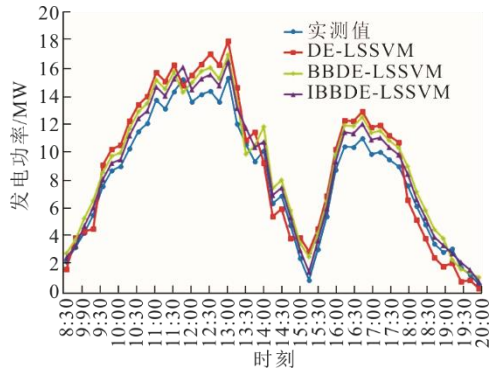


图3 雨天天气光伏发电功率预测结果

Fig.3 The prediction results of photovoltaic power generation in rainy weather

由图2、图3还可见,雨天天气下,光伏电站发

电功率明显降低。太阳辐射强度、大气温度和相对湿度变化剧烈,导致光伏功率波动较大,部分时刻预测误差较大。在3种模型中,本文模型预测的功率曲线更符合实际光伏发电功率曲线的变化趋势。

3种预测模型的预测误差指标见表2。由表2可以看出,晴天天气下,IBBDE-LSSVM模型预测结果的MAPE和RMSE指标分别为5.39%和3.98%,雨天天气下,IBBDE-LSSVM模型预测结果的MAPE和RMSE指标分别为10.69%和7.86%,均优于DE-LSSVM和BBDE-LSSVM模型的预测效果。由此表明,在不同的天气情况下,本文提出IBBDE-LSSVM模型具有更好的预测精度和稳定性。

表2 光伏发电功率预测误差指标对比

单位: %

Tab.2 The prediction error indexes for photovoltaic power generation

天气	DE-LSSVM		BBDE-LSSVM		IBBDE-LSSVM	
	σ_{MAPE}	σ_{RMSE}	σ_{MAPE}	σ_{RMSE}	σ_{MAPE}	σ_{RMSE}
晴天	8.46	5.69	7.28	4.49	5.39	3.98
雨天	15.63	10.87	14.21	9.77	10.69	7.86

4.3 算法性能分析

4.3.1 收敛性

为进一步比较本文提出IBBDE算法的优越性,对不同算法优化LSSVM模型的收敛性进行分析,结果如图4所示(以晴天天气为例)。由图4可以看出,IBBDE算法在第53代搜索出最优参数,而DE算法和IBBDE算法在搜索过程中陷入局部最优。由此验证IBBDE算法具有良好的全局寻优能力。

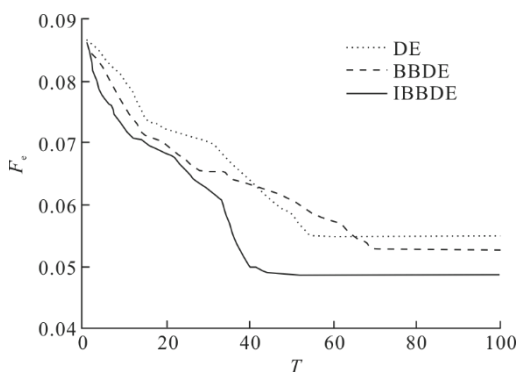


图4 不同光伏发电功率预测算法的收敛曲线

Fig.4 The convergence curves of different photovoltaic power prediction algorithms

4.3.2 参数敏感性

对IBBDE算法的种群规模敏感性进行分析。以雨天天气为例,不同种群规模下IBBDE-LSSVM模型预测效果见表3。由表3可以看出,随着种群

规模增加,模型预测精度未得到明显改善,优化过程的时间大幅增加。因此,IBBDE算法种群规模不必设置过大。

表3 不同种群规模IBBDE-LSSVM模型预测结果

Tab.3 The prediction results of the IBBDE-LSSVM model with different population sizes

N_p	$\sigma_{MAPE}/\%$	$\sigma_{RMSE}/\%$	运行时间/s
20	10.69	7.86	20.2
40	10.68	7.85	41.8
80	10.68	7.84	85.7

5 结 语

针对常规算法优化LSSVM模型进行短期光伏发电功率预测存在精度不高的问题,本文提出一种IBBDE算法优化LSSVM模型。该模型在BBDE算法的基础上,通过广义反向学习初始化种群和自适应调整交叉概率来提高算法的全局寻优能力。

以西藏林芝地区某光伏电站的实测数据为例进行仿真分析,结果表明,与DE和BBDE优化LSSVM模型相比,IBBDE优化LSSVM模型对短期光伏发电功率进行预测具有更高的预测精度和更好的稳定性,该方法能够满足工程应用需求。

[参 考 文 献]

- [1] 赖昌伟,黎静华,陈博. 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.
- [2] 张玉, 黄睿, 张振涛, 等. 基于克里格模型的光伏发电量预测[J]. 热力发电, 2017, 46(4): 27-32.
ZHANG Yu, HUANG Rui, ZHANG Zhentao, et al. Photovoltaic power generation prediction based on Krigemodel[J]. Thermal Power Generation, 2017, 46(4): 27-32.
- [3] 何锋, 章义军, 章建华, 等. 基于相似日和分位数回归森林的光伏发电功率概率密度预测[J]. 热力发电, 2019, 48(7): 64-69.
HE Feng, ZHANG Yijun, ZHANG Jianhua, et al. Forecasting of photovoltaic power generation probability density based on similar day and quantile regression forests[J]. Thermal Power Generation, 2019, 48(7): 64-69.
- [4] LI Y, SU Y, SHU L. An ARMAX model for forecasting the power output of a grid connected photovoltaic system[J]. Renewable Energy, 2014, 66(6): 78-89.
- [5] PERSSON C, BACHER P, SHIGA T, et al. Multi-site solar power forecasting using gradient boosted regression trees[J]. Solar Energy, 2017, 150: 423-436.
- [6] 侯伟, 肖健, 牛利勇. 基于灰色理论的光伏发电系统出力预测方法[J]. 电气技术, 2016, 17(4): 53-58.
HOU Wei, XIAO Jian, NIU Liyong. Analysis of power generation capacity of photovoltaic power generation system in electric vehicle charging station[J]. Electrical Engineering, 2016, 17(4): 53-58.
- [7] YANG C, THATTE A A, XIE L. Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation[J]. IEEE Transactions on Sustainable Energy, 2015, 6(1): 104-112.
- [8] 王育飞, 付玉超, 孙路, 等. 基于混沌-RBF神经网络的光伏发电功率超短期预测模型[J]. 电网技术, 2018, 42(4): 1110-1116.
WANG Yufei, FU Yuchao, SUN Lu, et al. Ultra-short term prediction model of photovoltaic output power based on chaos-RBF neural network[J]. Power System Technology, 2018, 42(4): 1110-1116.
- [9] 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 Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149-154.
- [10] 刘念, 张清鑫, 李小芳. 基于核函数极限学习机的分布式光伏短期功率预测[J]. 农业工程学报, 2014, 30(4): 152-159.
LIU Nian, ZHANG Qingxin, LI Xiaofang. Distributed photovoltaic short-term power output forecasting based on extreme learning machine with kernel[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(4): 152-159.
- [11] 张玉, 莫寒, 张烈平. 基于模糊支持向量机的光伏发电功率预测[J]. 热力发电, 2017, 46(1): 116-120.
ZHANG Yu, MO Han, ZHANG Lieping. Photovoltaic power prediction based on fuzzy support vector machine[J]. Thermal Power Generation, 2017, 46(1): 116-120.
- [12] 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. Prediction of short-term photovoltaic generation power based on HIMVO-SVM[J]. Thermal Power Generation, 2020, 49(4): 87-92.
- [13] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. Neural Network Letters, 1999, 9(3): 293-300.
- [14] 杨洪, 古世甫, 崔明东, 等. 基于遗传优化的最小二乘支持向量机风电场风速短期预测[J]. 电力系统保护与控制, 2011, 39(11): 44-48.
YANG Hong, GU Shifu, CUI Mingdong, et al. Forecast of short-term wind speed in wind farms based on GA optimized LS-SVM[J]. Power System Protection and Control, 2011, 39(11): 44-48.
- [15] 王贺, 胡志坚, 张翌晖, 等. 基于 IPSO-LSSVM 的风电功率短期预测研究[J]. 电力系统保护与控制, 2012, 40(24): 107-112.
WANG He, HU Zhijian, ZHANG Yihui, et al. Short-term prediction of wind power based on IPSO-LSSVM[J]. Power System Protection and Control, 2012, 40(24): 107-112.
- [16] 张文广, 张越, 孙亚洲, 等. 最小二乘支持向量机联合改进果蝇优化算法的 CFB 锅炉燃烧优化[J]. 热力发电, 2016, 45(7): 44-49.
ZHANG Wenguang, ZHANG Yue, SUN Yazhou, et al. Combustion optimization for CFB boiler based on least square support vector machine and modified fruit fly optimization algorithm[J]. Thermal Power Generation, 2016, 45(7): 44-49.
- [17] 陈磊, 陈李. 差分进化最小二乘支持向量机法预测日用水量[J]. 哈尔滨工业大学学报, 2018, 50(8): 83-87.
CHEN Lei, CHEN Li. Application of differential evolution and least squares support vector machine method in daily water demand prediction[J]. Journal of Harbin Institute of Technology, 2018, 50(8): 83-87.
- [18] WANG H, RAHNAMAYAN S, SUN H, et al. Gaussian bare-bones differential evolution[J]. IEEE Transactions on Cybernetics, 2013, 43(2): 634-647.
- [19] 丁成, 王秋萍, 王晓峰. 基于广义反向学习的磷虾群算法及其在数据聚类中的应用[J]. 计算机应用, 2019, 39(2): 336-342.
DING Cheng, WANG Qiuping, WANG Xiaofeng. Krill herd algorithm based on generalized opposition-based learning and its application in data clustering[J]. Journal of Computer Applications, 2019, 39(2): 336-342.
- [20] 许美玲, 王依雯. 基于改进差分进化和回声状态网络的时间序列预测研究[J]. 自动化学报, 2019. DOI: 10.16383/j.aas.c180549.
XU Meiling, WANG Yiwen. Time series prediction based on improved differential evolution and echo state network[J]. Acta Automation Sinica, 2019. DOI: 10.16383/j.aas.c180549.

(责任编辑 杜亚勤)