

DOI: 10.13234/j.issn.2095-2805.2025.1.143

中图分类号: TM615

文献标志码: A

基于 SOA-SVM 模型的光伏阵列故障 诊断研究

孙培胜, 陈堂贤, 程 陈, 李 正
(三峡大学电气与新能源学院, 宜昌 443002)

摘要: 针对支持向量机 SVM(support vector machine)用于光伏阵列故障诊断时准确率不高、且易受核函数与惩罚因子参数影响的问题, 提出 1 种基于海鸥优化算法 SOA(seagull optimization algorithm)支持向量机的光伏阵列故障诊断方法。引入海鸥优化算法对 SVM 模型进行参数寻优, 建立基于最优参数的 SOA-SVM 故障诊断模型; 利用 MATLAB 软件搭建光伏阵列仿真模型, 提取不同故障类型下的特征参数并输入到 SOA-SVM 模型进行故障诊断。实验结果表明: 经 SOA 优化后的 SVM 模型故障诊断准确率显著提高, 且相比于基于人工蜂群 ABC(artificial bee colony)算法的 ABC-SVM 模型和基于粒子群优化 PSO(particle swarm optimization)算法的 PSO-SVM 模型, SOA-SVM 模型具有更快的寻优收敛迭代速度和更高的故障诊断准确率。

关键词: 光伏阵列; 故障诊断; 海鸥优化算法; 支持向量机

Research on Fault Diagnosis of Photovoltaic Array Based on SOA-SVM Model

SUN Peisheng, CHEN Tangxian, CHENG Chen, LI Zheng

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Aimed at the problem that the accuracy of photovoltaic array fault diagnosis based on support vector machine (SVM) is not high and it is easily affected by the kernel function and penalty factor parameters, a photovoltaic array fault diagnosis method based on SVM optimized by the seagull optimization algorithm (SOA) is proposed. The SOA is introduced to optimize the parameters of the SVM model, and an SOA-SVM fault diagnosis model based on the optimal parameters is established. MATLAB software is used to build a photovoltaic array simulation model, and the characteristic parameters under different fault types are extracted and further inputted into the SOA-SVM model for fault diagnosis. Experimental results show that the fault diagnosis accuracy of the SVM model optimized by SOA is significantly improved. Compared with the ABC-SVM and PSO-SVM models, the SOA-SVM model converges faster in the optimization process and has a higher fault diagnosis accuracy.

Keywords: Photovoltaic array; fault diagnosis; seagull optimization algorithm (SOA); support vector machine (SVM)

在“双碳”目标下, 新能源发电技术呈现高速发展态势。光伏发电因地域限制小、规模灵活、清洁安全等优点, 正成为我国新能源发展的关键力量^[1]。但由于光伏阵列工作环境复杂, 容易发生光

伏组件老化、短路、开路、局部遮阴等故障, 降低光伏发电效率, 缩短光伏阵列使用寿命^[2]。因此, 进行快速准确的故障诊断对于光伏发电系统具有重要意义。

目前, 机器学习技术被大量运用于故障诊断研究, 如神经网络^[3]、极限学习机^[4]和支持向量机^[5]等。文献[6]利用遗传算法对反向传播 BP (back propagation)神经网络进行优化, 解决其易陷入局部最优的问题, 准确完成对光伏阵列的故障

收稿日期: 2022-05-12; 修回日期: 2022-06-26; 录用日期: 2022-07-07; 网络首发日期: 2022-08-23

基金项目: 国家自然科学基金资助项目(61603212)

This work is supported by National Natural Science Foundation of China under the grant 61603212

诊断;文献[7]利用布谷鸟算法优化神经网络对光伏组件进行故障诊断,提升了预测精度;文献[8]利用 K 均值聚类算法优化径向基函数 RBF(radial basis function)神经网络的参数选取过程进行光伏组件故障诊断,获得较高的故障诊断准确率;文献[9]建立基于高斯核函数的支持向量机 SVM(support vector machine)模型,可较为精准地判别光伏阵列各类型故障。

SVM 模型用于故障诊断能获得较高的准确率^[10],但仍存在一些不足:SVM 部分参数的设置对整体诊断精确度影响较大;部分改进模型中使用的优化算法,如人工蜂群 ABC(artificial bee colony)算法、粒子群优化 PSO(particle swarm optimization)算法,存在收敛速度慢、陷入局部最优等问题^[11-12]。为此,本文提出 1 种基于海鸥优化算法 SOA(seagull optimization algorithm)优化支持向量机的方法。针对惩罚因子与核函数参数对支持向量机辨识结果影响大的问题,引入海鸥优化算法进行参数寻优,进而建立 1 种基于 SOA-SVM 的故障诊断模型。通过仿真实验与 ABC-SVM、PSO-SVM 模型进行对比,结果表明 SOA-SVM 模型具有更快的收敛迭代速度和更高的故障诊断准确率,可有效进行光伏阵列故障诊断。

1 理论基础

1.1 支持向量机

支持向量机具有样本需求低、训练时间短、分类识别效果好、泛化能力强等优点^[13],因此常被用于故障诊断。SVM 的核心概念在于构建 1 个最优超平面^[14]将不同数据分类,并使分类间隔最大。如图 1 所示, H 为超平面, H_1 、 H_2 是相对 H 平行且距离相等的分类面,当 H_1 与 H_2 的间距 M 达到最大,若待分类的数据样本线性可分,则此超平面 H 为最优超平面。

对于非线性可分的数据,如图 2 所示,可通过核函数将样本数据映射到更高维度的空间,将最优分类超平面由低维不可建变为高维可建,进而对数

据分类,使得高维数据能使用线性分类方法,从而提高分类的泛化能力和置信度。




图 1 线性可分数据分类

Fig. 1 Classification of linear separable data




图 2 非线性可分数据分类

Fig. 2 Classification of nonlinear separable data

SVM 的最优超平面分类函数为

$$f(x) = \text{sgn} \left[\sum_{i=1}^n \alpha_i y_i K(x_i \cdot x) + b \right] \quad (1)$$

式中: α_i 为拉格朗日乘子,且 $0 \leq \alpha_i \leq C$,其中 C 为非负的惩罚因子,调节训练错误数与泛化能力之间的折中关系,能确保分类准确率, C 值越大训练错误分类越少, C 值越小训练错误分类越多; x_i 与 y_i 分别为样本集 T 中的特征向量与样本标签, $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}$; $K(x_i \cdot x)$ 为核函数; b 为训练样本确定的分类阈值。

选取不同核函数将影响 SVM 的分类能力和应用范围,常用核函数有线性核函数、多项式核函数、高斯核函数、Sigmoid 核函数等^[15]。线性核函数主要用于低维度线性可分的数据样本;多项式核函数参数较多,计算复杂;高斯核函数具有参数少、非线性映射和收敛速度快等优点。因此,本文选择高斯核函数,其大小可表示为

$$K(x_i \cdot x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2g^2} \right) \quad (2)$$

式中: g 为核函数参数; x_j 为样本集 T 中的不同样本的特征向量。

1.2 海鸥优化算法

SOA 算法是 Dhiman 等^[16]提出的 1 种基于种群的新型搜索算法, 可用于解决各领域优化问题。该算法通过模拟海鸥种群的迁徙与觅食行为分别实现全局搜索与局部搜索的功能, 全局搜索用于快速定位最优解范围, 局部搜索用于找到最优解。

1) 海鸥迁徙行为分析

为避免迁徙过程中不同海鸥个体之间的碰撞, 以及所有海鸥朝最佳位置靠近, 需要更新海鸥的位置, 即有

$$\begin{cases} C_s(t) = AP_s(t) \\ M_s(t) = B[P_{best}(t) - P_s(t)] \\ D_s(t) = |C_s(t) + M_s(t)| \end{cases} \quad (3)$$

式中: $C_s(t)$ 为海鸥不发生碰撞的新位置; $M_s(t)$ 为海鸥最佳位置所在方向; $D_s(t)$ 为海鸥更新后的新位置; $P_s(t)$ 为海鸥当前位置; $P_{best}(t)$ 为最佳海鸥位置; t 为迭代次数; A 为附加变量, 用于模拟海鸥在搜索空间的运动; B 为平衡算法局部与全局搜索的随机参数。 A 和 B 的大小可表示为

$$A = f_c - t \frac{f_c}{t_{max}} \quad (4)$$

$$B = 2A^2 \cdot rd \quad (5)$$

式中: f_c 为根据迭代次数变化的变量, 由 2 线性下降至 0; t_{max} 为最大迭代次数; rd 为 [0,1] 内的随机数。

2) 海鸥觅食行为分析

海鸥在觅食时产生攻击行为, 会不断改变攻击角度与飞行螺旋半径, 其在三维空间中的位置更新可表示为

$$\begin{cases} P_s(t+1) = D_s(t)xyz + P_{best}(t) \\ x = r \cos k \\ y = r \sin k \\ z = rk \end{cases} \quad (6)$$

式中: k 为 $[0, 2\pi]$ 范围内的随机角度; r 为海鸥的螺旋半径, $r = ue^{kv}$, 其中 u 和 v 为与螺旋形状相关的参数。

2 基于 SOA 优化 SVM 的故障诊断模型

2.1 光伏阵列故障仿真模型

通过 MATLAB/Simulink 软件搭建如图 3 所示的 6 行 6 列光伏阵列, 模拟其在不同运行条件下的故障并获取样本数据。仿真模拟光伏阵列 5 种运行状态: 正常运行; 光伏组件短路故障, 通过短接单个电气模块来模拟; 内部组件开路故障, 通过断开某组件支路来模拟; 局部阴影故障, 通过减小部分光伏组件的光照强度模拟; 光伏组件老化故障, 通过在支路中串联小电阻来模拟。




图 3 光伏阵列仿真模型

Fig. 3 Simulation model of photovoltaic array

每个光伏组件的电气参数相同: 最大功率点电流为 8.1 A, 最大功率点电压为 30.2 V, 开路电压为 37.2 V, 短路电流为 8.62 A, 光照强度范围为 600~1 000 W/m², 温度范围为 25~40 °C。仿真得到的电流-电压($I-U$)特性曲线与功率-电压($P-U$)特性曲线分别如图 4 与图 5 所示。

由图 4 和图 5 可见, 相较于正常运行状态, 短路故障时, 光伏阵列的开路电压明显减小, 最大功率点的电压与电流减小; 老化故障时, 最大功率点的电流与电压变化明显, 短路电流与开路电压无明显变化; 开路故障时, 短路电流明显减小; 局部阴影故障时, $P-U$ 特性曲线出现“多峰”现象, $I-U$ 特性曲线呈阶梯性变化。光伏阵列仿真所得典型运

行数据见表 1。




图 4 不同运行状态的 $I-U$ 特性曲线

Fig. 4 $I-U$ characteristic curves in different running states




图 5 不同运行状态的 $P-U$ 特性曲线

Fig. 5 $P-U$ characteristic curves in different running states

表 1 不同运行状态典型数据

Tab. 1 Typical data in different running states

系统参数	运行状态				
	正常	短路	老化	开路	阴影
短路电流 I_{sc}/A	55.41	55.41	55.39	46.20	55.41
开路电压 U_{oc}/V	205.48	191.61	208.2	205.50	207.30
最大功率点 电流 I_{pm}/A	51.03	51.48	47.84	42.52	51.30
最大功率点 电压 U_{pm}/V	170.48	156.61	169.40	170.48	147.34

综上可知, 光伏阵列发生故障时, 短路电流、开路电压、最大功率点电流与最大功率点电压中, 至少存在 1 项系统参数与正常运行时产生明显变化。因此, 选择此 4 种数据作为故障诊断的输入变量, 进而进行不同类型的故障识别。

2.2 SOA-SVM 故障诊断模型

作为 2 个重要参数, 惩罚因子 C 与核函数参数 g 直接影响支持向量机的故障诊断精度^[17], 因此如何快速有效寻找最优参数是优化算法的关键。引入 SOA 算法来优化支持向量机, 保证了搜索优化参数的准确性与速度, 使该分类诊断模型能快速、准确地得到最优参数, 进而进行故障诊断。

将 2.1 节仿真所得数据作为训练集与测试集, 通过 SOA-SVM 故障诊断模型进行分类诊断, 用适应度来判断分类诊断的准确率。适应度 fitness 的大小可表示为

$$\text{fitness} = \frac{\text{train}_w}{\text{train}_{\text{all}}} + \frac{\text{test}_w}{\text{test}_{\text{all}}} \quad (7)$$

式中: train_w 与 test_w 分别为训练集和测试集的错误诊断数量; $\text{train}_{\text{all}}$ 与 test_{all} 分别为训练集和测试集的样本总数。适应度 fitness 越小则表示诊断准确率越高。

SOA 优化 SVM 的故障诊断流程如图 6 所示, 其基本步骤如下。

步骤 1 输入正常运行及不同故障下的光伏阵列样本数据, 设置训练集与测试集, 并对数据归一化处理。

步骤 2 初始化 SVM 模型及 SOA 算法的参数, 并设置海鸥种群数量、最大迭代次数、自变量上、下限及维度大小。

步骤 3 随机生成海鸥种群, 每只海鸥位置都由对应参数 C 与 g 决定。

步骤 4 根据式(3)~式(7)对海鸥位置不断更新, 计算新位置的适应度, 并与更新前的适应度做比较, 保存更小的适应度作为当前最优值。

步骤 5 若更新到最优适应度或达到最大迭代次数, 则保存最优适应度; 否则, 返回步骤 4。

步骤 6 根据最优适应度保存对应的 SVM 参数组合(C, g)。

步骤 7 由式(1)和式(2)对 SVM 模型进行训练与测试。

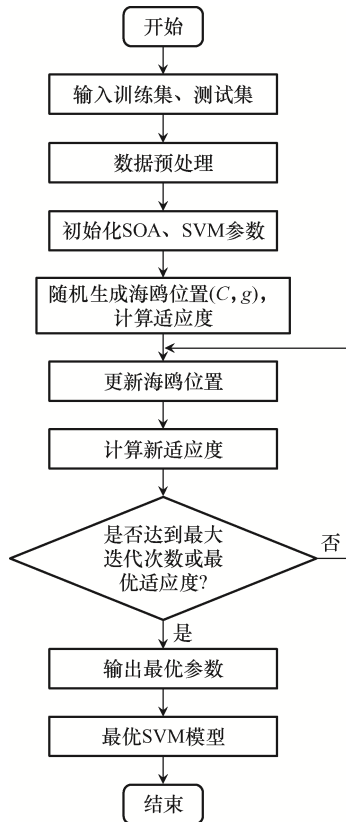


图 6 SOA 算法优化 SVM 流程
Fig. 6 Process of SVM optimized by SOA

3 光伏阵列故障诊断结果与分析

将 2.1 节仿真所得运行数据代入 2.2 节 SOA-SVM 故障诊断模型进行训练与测试。共计使用 500 组含故障状态标签的样本数据集, 其中正常(类别 1)运行状态 200 组, 老化(类别 2)状态 75 组, 阴影(类别 3)状态 75 组, 开路(类别 4)状态 75 组, 短路(类别 5)状态 75 组。随机选定 55 组数据作为测试集, 其他数据作为训练集。

惩罚因子 C 与核函数参数 g 的取值直接影响 SVM 的故障分类精度。对于未经参数优化的 SVM 模型, 在 $(0, 100]$ 范围内分别对 C 与 g 进行随机取值, 每对 (C, g) 能得到相应的诊断准确率, 不同取值次数下所得分类诊断结果如图 7 所示。由图 7 可见, (C, g) 随机取值的次数越多, 诊断准确率在 80% 以上的越多, 但多数情况诊断准确率保持在较低水平。因此, 采用未经参数优化的 (C, g) 将使 SVM 模

型所得诊断准确率较低且随机变化。




图 7 未优化 SVM 不同随机取值次数下诊断结果对比
Fig. 7 Comparison of diagnosis results under different random value times of unoptimized SVM

随机选取 1 组参数 ($C=19.4, g=1.6$), 所得未经参数优化的 SVM 模型诊断结果如图 8 所示, 预测结果显示, 该方法所得诊断准确率仅为 83.64%。其中, 4 组正常样本被诊断为组件开路, 1 组局部阴

影样本被诊断为正常, 4 组组件开路样本被诊断为正常。由此可见, 未经参数优化的 SVM 模型对数据分类诊断效果存在不足, 有待优化。




图 8 未优化 SVM 模型诊断结果

Fig. 8 Diagnostic result of unoptimized SVM model

使用 SOA 算法对 SVM 的惩罚因子 C 与核函数参数 g 进行参数寻优。设定 SOA-SVM 的参数如下: 种群规模 $N=8$, 最大迭代次数为 100, 惩罚因子 C 的范围为 $(0, 100]$, 核函数参数 g 的范围为 $(0, 100]$ 。故障诊断可视化结果如图 9 所示, 且寻优所得惩罚因子 $C=24.56$, 核函数参数 $g=0.1212$ 。




图 9 SOA-SVM 诊断结果

Fig. 9 Diagnostic result of SVM optimized by SOA

由图 9 可见, SOA-SVM 模型诊断结果中仅有 1 组老化故障数据被错误诊断为局部阴影故障, 分

类预测准确率达到 98.18%, 相比于未优化的 SVM 模型其准确率提升了 14.54%。结果表明 SOA-SVM 模型对光伏阵列的故障诊断较优化前更具可靠性。

为验证所提 SOA-SVM 分类模型的有效性, 参考文献[12-13]建立基于人工蜂群算法优化的 SVM 模型 ABC-SVM 与基于粒子群算法优化的 SVM 模型 PSO-SVM, 采用同一训练集数据与测试集数据进行诊断实验, 并与 SOA-SVM 模型所得结果进行对比, 不同迭代次数下的适应度曲线如图 10 所示。

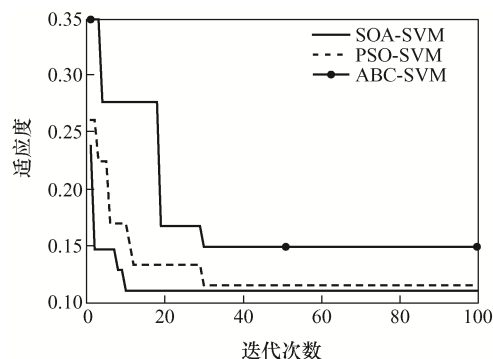


图 10 不同算法模型适应度曲线

Fig. 10 Fitness curves of different algorithm models

由图 10 可见, ABC 算法与 PSO 算法对于参数寻优过程的收敛迭代次数均大于 SOA 算法, 种群在搜索空间会更易陷入局部最优; SOA-SVM 算法模型的适应度最小, 表明诊断错误率最小。证明 SOA 算法可缓解传统算法在寻优过程中易陷入局部最优的问题。不同算法模型所得诊断分类准确率结果见表 2, 结果表明 SOA-SVM 模型具有最高的测试准确率 98.18%, 相比于 ABC-SVM 模型、PSO-SVM 模型分别提高了 3.63%、1.82%。综合寻优收敛迭代速度和诊断分类准确率可见, SOA-SVM 算法模型性能最好, 适用于本文中光伏阵列的故障诊断。

表 2 不同算法模型诊断结果

Tab. 2 Diagnostic results of different algorithm models

算法模型	训练准确率/%	测试准确率/%	收敛迭代次数	最优适应度
ABC-SVM	90.54	94.55	10	0.149 1
PSO-SVM	92.12	96.36	30	0.115 2
SOA-SVM	90.77	98.18	30	0.110 5


4 结语

本文提出 1 种基于海鸥算法优化支持向量机的光伏阵列故障诊断方法, 通过引入海鸥算法进行参数优化, 建立了 SOA-SVM 故障诊断模型。SOA 算法优异的全局搜索和局部搜索能力解决了传统算法模型存在的收敛迭代慢和易陷入局部最优的问题, 提高了 SVM 模型对光伏阵列的故障分类精度。与 ABC-SVM、PSO-SVM 模型相比, SOA-SVM 模型在分类诊断准确率、收敛迭代速度方面具有综合最优性能, 可将该模型用于其他类型的故障诊断。

参考文献:

- [1] 高伟, 黄俊铭. 基于 SSELN 的光伏组件故障智能诊断方法[J]. 太阳能学报, 2021, 42(12): 465-470.
Gao Wei, Huang Junming. Intelligent fault diagnosis method of photovoltaic module via SSELN [J]. Acta Energetica Solaris Sinica, 2021, 42(12): 465-470. (in Chinese)
- [2] 余玲珍, 覃涛, 龙道银, 等. TGBA 优化核极限学习机的光伏阵列故障诊断[J]. 激光杂志, 2021, 42(12): 140-148.
Yu Lingzhen, Qin Tao, Long Daoyin, et al. Fault diagnosis of PV array based on TGBA optimized kernel extreme learning machine [J]. Laser Journal, 2021, 42(12): 140-148. (in Chinese)
- [3] 宋文海, 李田泽, 田晖, 等. 基于概率神经网络的光伏阵列故障诊断研究[J]. 电源技术, 2019, 43(9): 1525-1527, 1567.
Song Wenhai, Li Tianze, Tian Hui, et al. Research on fault diagnosis of PV array based on PNN [J]. Chinese Journal of Power Sources, 2019, 43(9): 1525-1527, 1567. (in Chinese)
- [4] 陈世群, 高伟, 陈孝琪, 等. 一种基于极限学习机和皮尔逊相关系数的光伏阵列故障快速诊断方法[J]. 电气技术, 2021, 22(10): 57-64.
Chen Shiqun, Gao Wei, Chen Xiaoqi, et al. A fast fault diagnosis method for photovoltaic array via extreme learning machine and Pearson's correlation coefficient [J]. Electrical Engineering, 2021, 22(10): 57-64. (in Chinese)
- [5] 梅恒荣, 殷礼胜, 刘冬梅, 等. 改进粒子群算法优化的 SVM 模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(8): 1239-1246.
Mei Hengrong, Yin Lisheng, Liu Dongmei, et al. Analogue circuit fault diagnosis based on SVM optimized by IPSO [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(8): 1239-1246. (in Chinese)
- [6] 刘东, 李田泽, 刘开石, 等. GA-BP 神经网络在光伏阵列故障检测中的应用研究[J]. 电源技术, 2021, 45(3): 370-373.
Liu Dong, Li Tianze, Liu Kaishi, et al. Research on GA-BP neural network in photovoltaic array fault detection [J]. Chinese Journal of Power Sources, 2021, 45(3): 370-373. (in Chinese)
- [7] 张杰, 易辉, 张霞, 等. 基于布谷鸟算法的光伏组件故障诊断模型优化[J]. 电源技术, 2020, 44(1): 76-79.
Zhang Jie, Yi Hui, Zhang Xia, et al. Optimization of fault diagnosis model for photovoltaic module based on cuckoo algorithm [J]. Chinese Journal of Power Sources, 2020, 44(1): 76-79. (in Chinese)
- [8] 马纪梅, 张志耀, 张启然. 基于改进 RBF 神经网络的光伏组件故障诊断[J]. 电测与仪表, 2021, 58(2): 118-124.
Ma Jimei, Zhang Zhiyao, Zhang Qiran. Fault diagnosis of photovoltaic modules based on improved RBF neural network [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 118-124. (in Chinese)
- [9] 张晓鹏, 张兴忠. 基于高斯核函数的支持向量机光伏故障诊断研究[J]. 可再生能源, 2021, 39(6): 760-765.
Zhang Xiaopeng, Zhang Xingzhong. Research on photovoltaic fault diagnosis based on time domain characteristics [J]. Renewable Energy Resources, 2021, 39(6): 760-765. (in Chinese)
- [10] Wang Junjie, Gao Dedong, Zhu Shaokang, et al. Fault diagnosis method of photovoltaic array based on support vector machine [J]. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 2023, 45(2): 5380-5395.
- [11] 刘开石, 李田泽, 刘东, 等. 基于 ABC-SVM 算法的光伏阵列故障诊断[J]. 电源技术, 2021, 45(9): 1171-1174.
Liu Kaishi, Li Tianze, Liu Dong, et al. Fault diagnosis of

- PV array based on ABC-SVM algorithm [J]. Chinese Journal of Power Sources, 2021, 45(9): 1171-1174. (in Chinese)
- [12] 林培杰, 陈志聪, 吴丽君, 等. 一种 PSO-SVM 的光伏阵列故障检测与分类[J]. 福州大学学报(自然科学版), 2017, 45(5): 652-658.
- Lin Peijie, Chen Zhicong, Wu Lijun, et al. Fault detection and classification for photovoltaic arrays based on PSO-SVM [J]. Journal of Fuzhou University (Natural Science Edition), 2017, 45(5): 652-658. (in Chinese)
- [13] Tuerxun W, Xu Chang, Guo Hongyu, et al. Fault diagnosis of wind turbines based on a support vector machine optimized by the sparrow search algorithm [J]. IEEE Access, 2021, 9: 69307-69315.
- [14] Yin Zuyu, Hou Jian. Recent advances on SVM based fault diagnosis and process monitoring in complicated industrial processes [J]. Neurocomputing, 2016, 174: 643-650.
- [15] 尹嘉鹏. 支持向量机核函数及关键参数选择研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- Yin Jiapeng. Research on kernel function and key parameter selection of support vector machine [D]. Harbin: Harbin Institute of Technology, 2016. (in Chinese)
- [16] Dhiman G, Kumar V. Seagull optimization algorithm: Theory and its applications for large-scale industrial engineering problems [J]. Knowledge-Based Systems, 2019, 165: 169-196.
- [17] 李黄曼, 张勇, 张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(3): 123-129.
- Li Huangman, Zhang Yong, Zhang Yao. Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 123-129. (in Chinese)



孙培胜

作者简介:

孙培胜(1996—), 男, 通信作者, 硕士研究生。研究方向: 光伏发电故障诊断技术。E-mail: sps9610@163.com。

陈堂贤(1965—), 男, 学士副教授。研究方向: 柔性电力系统、风能及新能源发电技术。E-mail: 114830073@qq.com。

程陈(1998—), 男, 硕士研究生。研究方向: 光伏发电技术。E-mail: 839524742@qq.com。

李正(1997—), 男, 硕士研究生。研究方向: 柔性直流输电技术。E-mail: sdwfcylz@126.com。

(责任编辑: 郭凯凯)