

DOI: 10.13382/j.jemi.B2407438

# 基于 IGJO-DHKELM 的光伏阵列故障诊断\*

张彼德<sup>1</sup> 陈广<sup>1</sup> 廖其龙<sup>2</sup> 邱杰<sup>1</sup> 马俊梅<sup>1</sup> 何恒志<sup>1</sup> 阎铁生<sup>1</sup>

(1. 西华大学电气与电子信息学院 成都 610039; 2. 攀枝花学院电气信息工程学院 攀枝花 617000)

**摘要:**为提高光伏阵列故障诊断精度,提出一种基于改进金豺算法(improved golden jackal optimization, IGJO)优化深度混合核极限学习机(deep hybrid kernel limit learning machine, DHKELM)的光伏阵列故障诊断方法。首先,在 MATLAB/Simulink 仿真平台模拟各种光伏阵列故障,在对故障特征进行了深入分析的基础上,提出了一个 12 维特征作为光伏阵列故障诊断的特征量;其次,通过引入透镜成像反向学习策略、正余弦算法策略和自适应 T 分布扰动策略对金豺算法进行改进,以提高其收敛速度和全局寻优能力,并将 IGJO 与其他优化算法通过测试函数进行对比;再次,将径向基核函数和多项式核函数引入极限学习机,并结合自编码器构成 DHKELM 模型。最后,通过 IGJO 对 DHKELM 模型的初始参数进行优化,建立了 IGJO-DHKELM 光伏阵列故障诊断模型。结果分析表明,与传统 4 维和 5 维故障特征量相比,利用所提 12 维故障特征量进行诊断时准确率更高;相较于其他故障诊断模型,基于 IGJO-DHKELM 的光伏阵列故障诊断方法具有更高的诊断精度。

**关键词:** 光伏阵列;故障诊断;故障特征量;改进金豺算法;深度混合核极限学习机

**中图分类号:** TM615;TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Fault diagnosis of photovoltaic arrays based on IGJO-DHKELM

Zhang Bide<sup>1</sup> Chen Guang<sup>1</sup> Liao Qilong<sup>2</sup> Qiu Jie<sup>1</sup> Ma Junmei<sup>1</sup> He Hengzhi<sup>1</sup> Yan Tiesheng<sup>1</sup>

(1. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China;

2. School of Electrical and Information Engineering, Panzhihua University, Panzhihua 617000, China)

**Abstract:** To enhance the accuracy of photovoltaic (PV) array fault diagnosis, this study proposes a novel method that utilizes an improved golden jackal optimization (IGJO) algorithm to optimize a deep hybrid kernel extreme learning machine (DHKELM) for PV array fault diagnosis. Initially, a range of PV array faults are simulated using the MATLAB/Simulink platform. Based on a comprehensive analysis of fault characteristics, a 12-dimensional feature set is proposed for fault diagnosis. Subsequently, the golden jackal algorithm is improved by introducing lens imaging reverse learning strategy, cosine and sine algorithm strategy, and adaptive T-distribution perturbation strategy to enhance its convergence speed and global optimization capability. Additionally, IGJO is compared with other optimization algorithms using test functions. Furthermore, radial basis kernel functions and polynomial kernel functions are incorporated into the extreme learning machine and combined with an autoencoder to form the DHKELM model. Finally, IGJO is employed to optimize the initial parameters of the DHKELM model, resulting in the establishment of the IGJO-DHKELM PV array fault diagnosis model. Analysis of the results indicates that the proposed 12-dimensional feature set provides higher diagnostic accuracy compared to traditional 4-dimensional and 5-dimensional feature sets. Moreover, the IGJO-DHKELM-based fault diagnosis method demonstrates superior diagnostic accuracy compared to other fault diagnosis models.

**Keywords:** photovoltaic array; fault diagnosis; fault feature set; IGJO; DHKELM

## 0 引言

随着“双碳目标”的提出,新能源将在新型电力系统中占据主体地位。其中,光伏发电技术已显著提升,但户外复杂环境运行的光伏阵列易出现故障,影响其发电效率和寿命<sup>[1]</sup>。因此,提高光伏阵列故障诊断准确率至关重要。

当前,国内外众多学者针对光伏阵列故障诊断问题主要提出电路结构法、数学模型法、红外图像法和人工智能法<sup>[2]</sup>。电路结构法<sup>[3]</sup>将传感器与光伏组件结合起来完成故障诊断,可实现较为精确的故障定位,但该方法过于依赖传感器,从而大大提升了光伏发电系统的安装复杂度和花费,对于大型光伏电站经济性较低。数学模型法<sup>[4]</sup>将光伏阵列实测信号与其仿真模型进行对比分析,根据差异实现故障检测,该方法检测准确度高,但需要搭建精确的数学模型,增加成本。红外图像法<sup>[5-6]</sup>通过红外相机获取红外图像,根据温度差异来进行检测故障,不会对阵列结构产生影响,但该方法具有成本高、受环境影响大等问题,不适合广泛应用。近几年,人工智能算法<sup>[7-8]</sup>已取得显著进步,日渐完备。鉴于极限学习机(extreme learning machine, ELM)的卓越特性,研究人员将其应用于故障诊断领域<sup>[9]</sup>。文献[10]提出了一种哈里斯鹰算法优化 ELM 有效提高复合故障精度的诊断方法,其泛化性能有待提升。文献[11]将径向基函数(radial basis function, RBF)与 ELM 相结合形成核极限学习机(kernel limit learning machine, KELM)模型,提高了模型的拟合能力,但其在优化参数方面还需提高。文献[12]将径向基核函数和多项式核函数结合建立了一种混合核极限学习机(hybrid kernel limit learning machine, HKELM)模型,进一步提高了模型的数据处理能力,但在特征提取方面有待提高。文献[13]将深度学习中的自编码器思想与 ELM 相结合堆叠构成深度极限学习机(deep extreme learning machine, DELM),增强了模型的表征能力,可能存在过拟合问题。文献[14]建立了一种深度核极限学习机的故障诊断模型,提高了模型在特征提取方面的能力,但在面对高维复杂数据时有一定的局限性,没有取得较好的解决。

针对上述不足,学者们通过优化算法对模型进行参数寻优,提高模型的性能。常见的优化算法有灰狼算法<sup>[15]</sup>(grey wolf optimization, GWO)、鲸鱼算法<sup>[16]</sup>(whale optimization algorithm, WOA)、麻雀算法<sup>[17]</sup>(sparrow search algorithm, SSA)和金豺算法<sup>[18]</sup>(golden jackal optimization, GJO)等。其中 GJO 的是 2022 年被提出的一种新型元启发式优化算法,具有结构简单、参数少等优点,但仍存在着收敛速度慢和迭代后期易陷入局部最优等问题,引起

了学者们的广泛关注。

综合上述分析,提出一种改进金豺优化算法(improved golden jackal optimization, IGJO)优化深度混合核极限学习机(deep hybrid kernel limit learning machine, DHKELM)的光伏阵列故障诊断方法。首先,通过 MATLAB/Simulink 仿真平台模拟光伏阵列故障,并分析确定故障特征量。然后,引入透镜成像反向学习策略<sup>[19]</sup>、正余弦算法策略<sup>[20]</sup>和自适应  $t$  分布策略<sup>[21]</sup>改进金豺优化算法,并通过 3 种典型的测试函数对 IGJO 的性能进行测试,以证明其具有更好的搜索能力和寻优精度。再运用不同的核函数组合并加权形成 DHKELM,旨在提高模型的准确率,同时采用 IGJO 对 DHKELM 的超参数进行优化。最后,对所提故障诊断模型进行验证分析。

## 1 光伏阵列故障特征选取

光伏阵列一般由多个光伏组件串并联连接方式组成<sup>[22]</sup>。本文使用 MATLAB/Simulink 仿真软件搭建了  $6 \times 4$  的光伏阵列仿真模型,如图 1 所示。

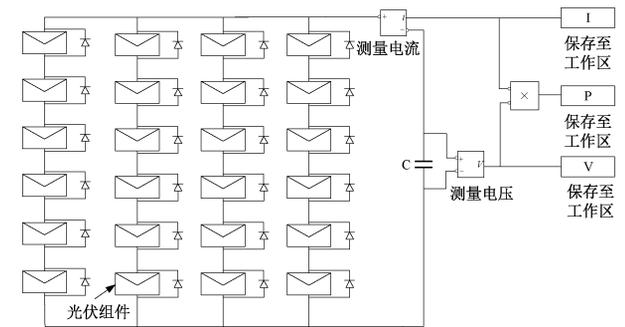


图 1 光伏阵列仿真模型

Fig. 1 Simulation model of photovoltaic array

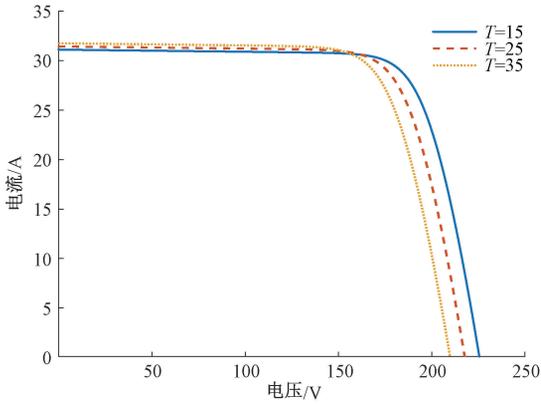
选取合适的故障特征对于提高故障诊断系统的精度与效率至关重要<sup>[23]</sup>。光伏阵列的输出电流、输出电压以及输出功率易受环境影响,其环境因素主要是太阳辐照度  $G$  和温度  $T$ ;当阵列发生单一故障或复合故障时也会导致这三者的变化,从而使得故障诊断变得复杂。对光伏阵列模型在正常与故障工作状态下进行了详细的仿真与分析,研究选用的太阳能光伏组件参数如表 1 所示。

表 1 光伏组件参数

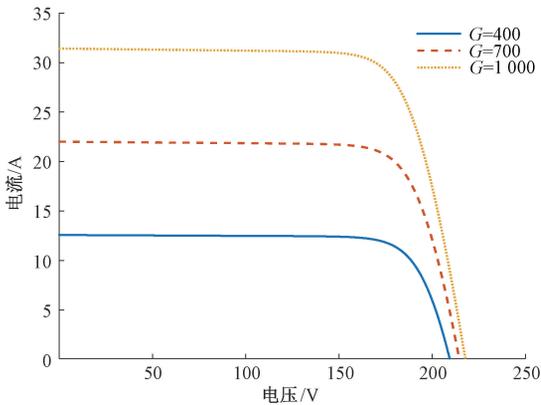
Table 1 The parameters of photovoltaic modules

参数	值
开路电压/ $(U_{oc} \cdot V^{-1})$	36.3
短路电流/ $(I_{sc} \cdot A^{-1})$	7.84
最大功率电压/ $(U_m \cdot V^{-1})$	29
最大功率电流/ $(I_m \cdot A^{-1})$	7.35
最大功率/ $(P_m \cdot W^{-1})$	213.15

正常状态下不同太阳辐照度和温度的特性曲线如图 2 所示。图 2 表明,光伏阵列的  $I-V$  特性曲线明显受太阳辐照度和温度影响。如图 2(a) 所示,随着温度的增加,  $U_{oc}$  降低,  $I_{sc}$  变化不大;从图 2(b) 可以看出,当太阳辐照度增大时,  $I_{sc}$  和  $U_{oc}$  都呈现上升趋势。



(a) Different temperatures  
(a) Different temperatures



(b) Different solar irradiances  
(b) Different solar irradiances

图 2 不同温度和太阳辐照度下的  $I-V$  特性曲线

Fig. 2  $I-V$  characteristic curves under different temperatures and solar irradiance levels

光伏阵列的常见故障包括开路、短路、老化和遮阴故障。光伏组件之间的串联线断裂,导致电流不能流通,形成开路故障,可通过断开光伏串支路模拟故障;短路故障是阵列中不同电位点连接造成,通过短接组件模拟故障;光伏阵列老化故障是由于长时间运行造成组件内的并联电阻减小或是串联电阻增大,一般通过串联  $5\ \Omega$  电阻模拟故障;在实际情况下,光伏阵列易受云、树木等遮挡形成局部遮阴现象,影响光伏阵列的输出功率,遮阴故障通过设置屏蔽系数进行模拟,本文设置屏蔽系数为 0.6。

有时,在多种因素影响下会导致多种故障同时发生。在所有故障情况中,局部遮阴和老化故障最可能长时间存在,导致复合故障发生。甚至在一些缺乏人工或智能化运维的地方,会面临同时发生两个或两个以上的故障,

这将造成非常严重的后果。对单一故障和复合故障进行描述如表 2 所示,其特性曲线如图 3 所示。

表 2 光伏阵列的故障类型

Table 2 The type of failure of the PV array

标签	故障描述
A <sub>1</sub>	无故障
A <sub>2</sub>	只有开路故障
A <sub>3</sub>	只有短路故障
A <sub>4</sub>	只有老化故障
A <sub>5</sub>	只有局部遮阴故障
A <sub>6</sub>	开路故障和老化故障
A <sub>7</sub>	短路故障和老化故障
A <sub>8</sub>	局部遮阴和老化故障
A <sub>9</sub>	局部遮阴和短路故障
A <sub>10</sub>	局部遮阴和开路故障
A <sub>11</sub>	局部遮阴、老化故障和开路故障
A <sub>12</sub>	局部遮阴、老化故障和短路故障

由图 3 可知,当光伏阵列处于 A<sub>2</sub>、A<sub>6</sub>、A<sub>10</sub> 和 A<sub>11</sub> 状态下时,  $I_{sc}$  和最大功率点变化明显;当光伏阵列处于 A<sub>3</sub>、A<sub>7</sub>、A<sub>9</sub> 和 A<sub>12</sub> 状态下时,  $U_{oc}$  发生明显变化,最大功率点发生偏移;当光伏阵列处于 A<sub>4</sub>、A<sub>5</sub> 和 A<sub>8</sub> 状态下,  $I_{sc}$  和  $U_{oc}$  无明显变化,最大功率点发生变化。

综合上述分析可得,光伏阵列在不同工作状态下,输出量可能会发生显著变化,一般选取  $G$ 、 $T$ 、 $I_{sc}$ 、 $U_{oc}$ 、 $I_m$ 、 $U_m$  为故障特征量,并记为  $F_1 \sim F_6$ 。但是,在光伏阵列处于 A<sub>4</sub>、A<sub>5</sub>、A<sub>7</sub>、A<sub>8</sub>、A<sub>9</sub> 状态下,其特性曲线比较相近,最大功率点、 $I_{sc}$  和  $U_{oc}$  相差不大;且由图 2 可知,当  $G$  和  $T$  发生变化时,其特性曲线也会产生较大的变化,仅仅选取  $F_1 \sim F_6$  作为故障特征量难以使得不同工况下的不同故障得到全面的体现。因此,为了使得故障信息得到更多的体现,本文还选取了以下故障特征量<sup>[24]</sup>:

$$F_7 = \frac{I_m U_m}{I_{sc} U_{oc}} \quad (1)$$

$$F_8 = \frac{I_m}{I_{sc}} \quad (2)$$

$$F_9 = \frac{U_{oc}}{I_m} \quad (3)$$

$$F_{10} = \frac{U_m}{I_{sc}} \quad (4)$$

$$F_{11} = \frac{U_m}{U_{oc}} \quad (5)$$

$$F_{12} = \frac{I_m}{U_m - U_{oc}} \quad (6)$$

其中,  $F_7$  表示填充因子,可以较好反映组件故障程度;  $F_8 \sim F_{11}$  表示  $I_m$ 、 $U_m$ 、 $I_{sc}$ 、 $U_{oc}$  之间的比例关系;  $F_{12}$  表示  $I-V$  特性曲线中最大功率点和开路点之前连线的斜率。

## 2 金豺优化算法及其改进

### 2.1 金豺优化算法

GJO 是由 Chopra 等于 2022 年提出的一种新型元启发式优化算法,该算法主要模拟了金豺对合作狩猎的行为。

金豺种群在搜索空间内随机初始化,其表达式为:

$$Y_0 = b + \text{rand}(a - b) \quad (7)$$

式中: $a$  和  $b$  分别表示解的上界和下界; $\text{rand}$  表示  $[0, 1]$  之间的随机数。

对全部个体进行适应度计算并排序,选择适应度值最大的作为雄性金豺,第 2 大的作为雌性金豺,并将其组成金豺对。狩猎阶段由雄性豺狼主导,雌性豺狼跟随,其搜索公式为:

$$Y_1(t) = Y_M(t) - E \cdot |Y_M(t) - \mathbf{rl} \cdot \mathbf{Prey}(t)| \quad (8)$$

$$Y_2(t) = Y_{FM}(t) - E \cdot |Y_{FM}(t) - \mathbf{rl} \cdot \mathbf{Prey}(t)| \quad (9)$$

式中: $t$  为当前迭代次数, $\mathbf{Prey}(t)$  为猎物的位置向量, $Y_M(t)$  和  $Y_{FM}(t)$  为雄性豺狼和雌性豺狼的位置, $Y_1(t)$  和  $Y_2(t)$  对应雄性豺狼与雌性豺狼更新后的位置。 $E$  为猎物躲避的能量,其计算公式如式(10)~(12)所示。

$$E = E_1 \times E_0 \quad (10)$$

$$E_0 = 2 \times r - 1 \quad (11)$$

$$E_1 = c_1 \times \left(1 - \left(\frac{t}{T}\right)\right) \quad (12)$$

式中: $E_0$  为初始能量状态, $r$  为  $[0, 1]$  之间的随机数, $c_1$  是常数为 1.5, $E_1$  为一个线性衰减的能量, $T$  为最大迭代次数。

$\mathbf{rl}$  为基于 Levy 分布的向量,其公式为:

$$\mathbf{rl} = 0.05 \times LF(y) \quad (13)$$

$LF$  为莱维飞行函数,其公式如式(14)所示。

$$\left\{ \begin{array}{l} LF(y) = 0.01 \times \frac{(\mu \times \sigma)}{(|v| \left(\frac{1}{\beta}\right))} \\ \sigma = \left( \frac{\Gamma(1 + \beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \times \beta \times (2^{\frac{\beta-1}{2}})} \right) \end{array} \right. \quad (14)$$

式中: $\mu$  和  $v$  为  $[0, 1]$  中的随机值, $\beta = 1.5$ 。

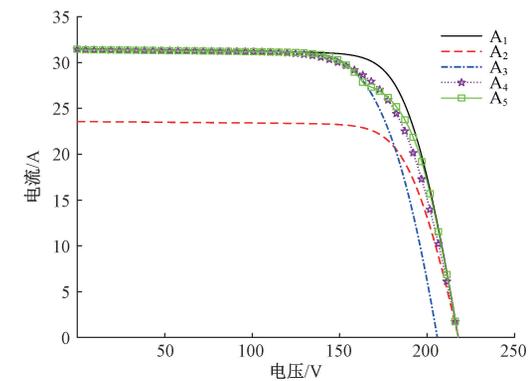
金豺的位置更新公式为:

$$Y(t+1) = \frac{Y_1(t) + Y_2(t)}{2} \quad (15)$$

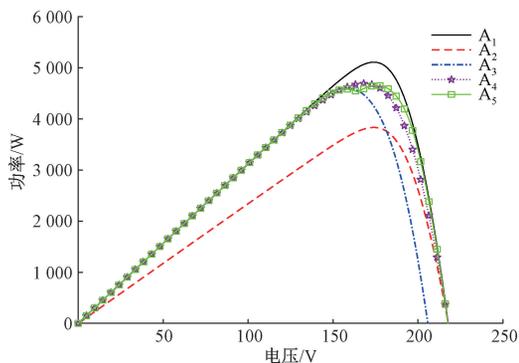
当猎物遭受豺狼骚扰时,其躲避能量会快速降低,此时豺狼对会迅速包围猎物并攻击它。其位置计算公式为:

$$Y_1(t) = Y_M(t) - E \cdot |\mathbf{rl} \cdot Y_M(t) - \mathbf{Prey}(t)| \quad (16)$$

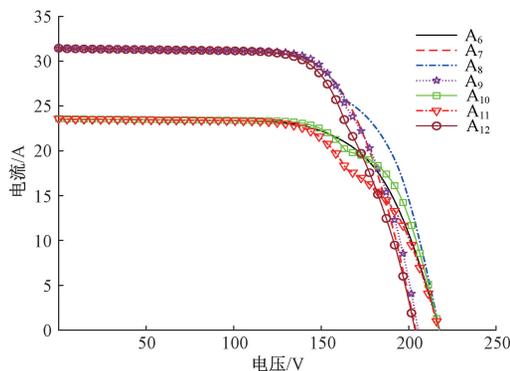
$$Y_2(t) = Y_{FM}(t) - E \cdot |\mathbf{rl} \cdot Y_{FM}(t) - \mathbf{Prey}(t)| \quad (17)$$



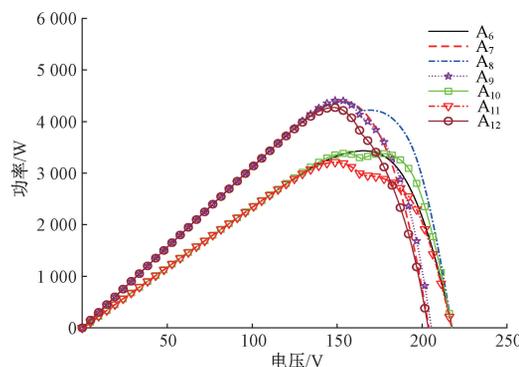
(a) 单一故障  $I$ - $V$  特性曲线  
(a)  $I$ - $V$  characteristic curve of single fault



(b) 单一故障  $P$ - $V$  特性曲线  
(b)  $P$ - $V$  characteristic curve of single fault



(c) 复合故障  $I$ - $V$  特性曲线  
(c)  $I$ - $V$  characteristic curve of compound fault



(d) 复合故障  $P$ - $V$  特性曲线  
(d)  $P$ - $V$  characteristic curve of compound fault

图 3 单一故障和复合故障的特性曲线

Fig. 3 Characteristic curves for single and compound faults

最后,通过式(15)更新豺狼位置。

### 2.2 改进金豺优化算法

针对 GJO 算法存在收敛较慢和在迭代后期由于种群多样性降低使得算法陷入局部最优的缺点,本文提出将透镜成像反向学习策略、正余弦策略以及自适应 T 分布扰动变异策略融合到 GJO 中,从而增强了 GJO 的全局寻优能力。

透镜成像反向学习策略是在当前解的基础上计算它的反向解,并利用其适应度函数值得到新的最优解,使得算法的搜索范围扩大,提高收敛速度。其更新位置公式为:

$$Y^* = \frac{a+b}{2} + \frac{a+b}{2 \times k} - \frac{Y}{k} \quad (18)$$

式中: $a$  和  $b$  分别表示解的上界和下界; $k$  为调节因子,其公式如式(19)所示。

$$k = \left(1 + \sqrt{\frac{t}{T}}\right)^{10} \quad (19)$$

受到正余弦优化算法的启发,为提高 GJO 的种群多样性,通过金豺最优位置的信息得到一个新的个体位置更新方式,再通过旧的位置进行更新,其公式为:

$$\begin{cases} r_1 = m \times \left(1 - \frac{t}{T}\right) \\ r_2 = m \times \pi \times rand \\ r_3 = m \times rand \end{cases} \quad (20)$$

$$\begin{cases} Y_{ij}^* = Y_{ij} + r_1 \sin(r_2) | r_3 Y_1 - Y_{ij} |, rand > 0.5 \\ Y_{ij}^* = Y_{ij} + r_1 \cos(r_2) | r_3 Y_1 - Y_{ij} |, 其他 \end{cases} \quad (21)$$

式中: $m$  常数,取值为 2; $r_1$  为控制搜索的方向; $Y_{ij}$  表示当前迭代第  $i$  个金豺在第  $j$  维的最优位置。

自适应 T 分布策略兼具柯西变异与高斯变异的特点,在迭代过程中通过自适应 T 分布对金豺位置进行扰

动,实现种群的变异,使得算法在迭代前期具有较好的全局开发能力,在迭代后期具有较好的跳出极值能力,进一步提高全局寻优能力,其公式为:

$$Y_i^t = Y_i + Y_i \cdot t(ite\text{r}) \quad (22)$$

式中: $ite\text{r}$  为自由度参数,公式为:

$$ite\text{r} = e^{4 \times \left(\frac{t}{T}\right)^2} \quad (23)$$

### 2.3 IGJO 性能测试

为验证本文所改进算法和所采取策略的有效性,采用不同策略与 GJO 结合获得以下两种算法:

1) 将通过透镜成像反向学习与 GJO 结合得到 LGJO;

2) 将透镜成像反向学习与正余弦策略融合到 GJO 中得到 LSGJO;

选取 GJO、LGJO、LSGJO、IGJO、GWO、WOA 和 SSA 进行测试函数对比实验,设置种群大小和最大迭代次数分别为 50 和 1 000。为降低实验结果的随机误差影响,对 3 个标准测试函数( $f_1$ 、 $f_2$ 、 $f_3$ )重复执行 10 次独立实验,之后,根据所得数据绘制适应度曲线,利用其收敛精度和速度进行评估,并将实验结果的最优值(best)、平均值(mean)以及标准差(std)当作评价指标;具体函数如表 3 所示,测试函数收敛曲线如图 4 所示,实验结果如表 4 所示。

表 3 标准测试函数

Table 3 Standard test function

函数	搜索范围	$f_{\min}$
$f_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	$[-10, 10]$	0
$f_3(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	$[-500, 500]$	-12 569.5

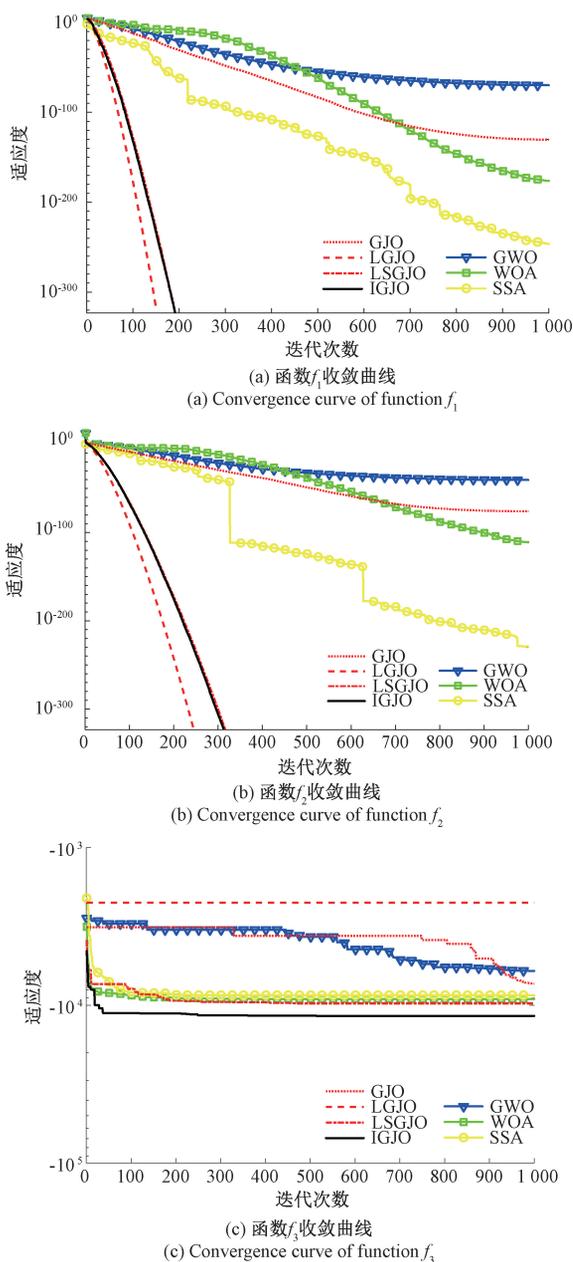
表 4 不同算法测试函数寻优结果对比

Table 4 Comparison of the optimization results of different algorithm test functions

函数名	指标	IGJO	GJO	LGJO	LSGJO	SSA	WOA	GWO
$f_1$	最优值	0	3.710 7×10 <sup>-157</sup>	0	0	0	1.330 4×10 <sup>-202</sup>	4.028 3×10 <sup>-88</sup>
	平均值	0	1.156 7×10 <sup>-151</sup>	0	0	0	2.023 4×10 <sup>-190</sup>	5.600 4×10 <sup>-86</sup>
	标准差	0	3.368 5×10 <sup>-151</sup>	0	0	0	0	7.258 5×10 <sup>-86</sup>
$f_2$	最优值	0	2.009 2×10 <sup>-89</sup>	0	0	0	2.881 9×10 <sup>-121</sup>	9.691 8×10 <sup>-50</sup>
	平均值	0	6.946 5×10 <sup>-88</sup>	0	0	8.06×10 <sup>-314</sup>	2.787 8×10 <sup>-113</sup>	2.182×10 <sup>-49</sup>
	标准差	0	8.191 4×10 <sup>-88</sup>	0	0	0	8.792 7×10 <sup>-113</sup>	9.620 1×10 <sup>-50</sup>
$f_3$	最优值	-12 299.445 1	-7 323.888 5	-3 954.783 6	-10 849.340 9	-10 255.379 7	-11 169.459 2	-8 893.142 1
	平均值	-11 389.732 8	-5 296.678 5	-2 755.850 5	-8 927.879 4	-9 100.707 6	-10 253.785 2	-6 715.266 2
	标准差	547.378 2	1 535.723 4	671.801 8	683.297 1	532.344 2	561.626 9	986.207 3

结合图 4 和表 4 的数据可以看出:在同一精度下,7 种优化算法中 LGJO、LSGJO、IGJO、SSA 均在函数  $f_1$  和  $f_2$

上的适应度达到最优,其中 LGJO 的迭代次数最少,随着迭代次数增多,GJO、GWO 和 WOA 的收敛趋势逐渐稳

图 4 函数  $f_1$   $f_2$   $f_3$  收敛曲线Fig. 4 Convergence curves of functions  $f_1$ ,  $f_2$ , and  $f_3$ 

定,呈现出收敛停滞的现象,且寻优精度较低。而在函数  $f_3$  上只有 IGJO 的适应度值接近最优。通过 LGJO 与 GJO 对比可以表明透镜成像反向学习策略大大提高了 GJO 的收敛速度,但在函数  $f_3$  中 LGJO 陷入局部最优。在函数  $f_3$  中对比 LSGJO 和 LGJO 可知正余弦策略对于提高 GJO 的种群多样性,打破局部最优有一定效果。3 个函数中 IGJO 均寻到最优,且收敛速度较快,表明了引入自适应 T 分布扰动策略增加了种群多样性,使得算法跳出局部极值的能力加强,进一步提升了全局寻优能力。

综上所述,IGJO 相对于其他 6 种算法在跳出极值能

力、寻优能力、收敛性等方面具有良好的性能,且在不同测试函数上的适应性较强。

### 3 深度混合核极限学习机

#### 3.1 混合核极限学习机

极限学习机(extreme learning machine, ELM)其本质视作一种特殊的前馈神经网络<sup>[25]</sup>,与传统的神经网络方法相比,ELM 在训练过程中随机初始化输入权重和偏置,具有训练速度快、泛化性强等优点。

假设有  $N$  个随机的样本数据  $(x_i, y_i)$ , 其中  $x_i$  为输入,  $y_i$  为输出,  $i=1, 2, 3, \dots, n$ 。ELM 的学习过程通过求最小二乘解的方式表征,如式(24)所示。

$$\beta^* = H^+ Y \quad (24)$$

式中:  $H^+$  为矩阵  $H$  的 Moore-Penrose 广义逆变换;  $Y$  是目标输出矩阵;  $\beta^*$  是输出权值矩阵。

由于核函数的非线性映射能力非常强大,将核函数与 ELM 结合构造而成的核极限学习机(KELM)具有更强的学习能力和泛化能力。本文引入核函数矩阵  $HH^T$ , 其表达式为:

$$\begin{cases} HH^T = K_{ELM} \\ K_{ELM} = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_n) \\ \vdots & \ddots & \vdots \\ K(x_n, x_1) & \cdots & K(x_n, x_n) \end{bmatrix} \end{cases} \quad (25)$$

式中:  $K(x, y)$  为核函数,  $K_{ELM}$  为核矩阵。

则 KELM 的模型输出表达式为:

$$y(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix} \left( \frac{E}{C} + K_{ELM} \right)^{-1} Y \quad (26)$$

式中:  $C$  表示正则化系数,  $E$  是单位矩阵。

为进一步提升 KELM 的性能,选择径向基核函数和多项式核函数,对这两种核函数加权组成混合核函数<sup>[26]</sup>。

径向基核函数可以将输入的样本映射到高维空间,具有较好的学习能力,其核函数表达式为:

$$K_{RBF}(x, x_i) = \exp\left(-\frac{\|x, x_i\|^2}{2\sigma^2}\right) \quad (27)$$

式中:  $\sigma$  是 RBF 核函数的参数。

多项式核函数具有很好的泛化性能,其核函数表达式为:

$$K_{poly}(x, x_i) = ((x \cdot x_i) + c)^d \quad (28)$$

式中:  $c$  为一个常数,  $d$  为多项式的次数。

混合核函数方程为:

$$K_{mix}(x, x_i) = wK_{RBF} + (1-w)K_{poly}, w \in [0, 1] \quad (29)$$

式中: 权重系数为  $w$ 。

### 3.2 基于极限学习机自编码器的深度混合核极限学习机

极限学习机自编码器 (ELM-AE) 是极限学习机 (ELM) 的一个变体,它能够有效地从输入数据中学习到重要的特征,并且保持输入与输出的对称性<sup>[27]</sup>。深度极限学习机 (DELM) 将 ELM-AE 当作基本级联单元构成,首先利用 ELM-AE 进行无监督的深度特征提取,然后通过 ELM 进行有监督分类。

DHKELM 融合了 DELM 与 HKELM 的特点,结构示意图如图 5 所示。其初始化过程如下所述:

步骤 1) 对 ELM-AE 模型中随机初始化的输入权重  $W_i$  和偏置  $b_i$  进行正交化处理。

步骤 2) 通过式 (30) 与式 (31) 可以得出对应隐含层节点的输出矩阵  $H_i$  与输出权重  $\beta_i$ ;

$$H_i = g(W_i \cdot X + b_i) \quad (30)$$

$$\beta_i = \left( \frac{E}{C} + H_i^T H_{i-1} \right)^{-1} H_i^T H_{i-1} \quad (31)$$

式中:  $g$  为激活函数,  $X$  为输入样本。

步骤 3) 通过式 (32) 计算每一层的 ELM-AE 的隐含层输出矩阵;

$$H_i = g(\beta_i^T H_{i-1}) \quad (32)$$

步骤 4) 最后一层隐含层的输出矩阵被用作 HKELM 的决策输入,并通过式 (33) 计算 HKELM 的输出权重。

$$\beta = \left( \frac{E}{C} + K_{ELM} \right)^{-1} H_i \quad (33)$$

DHKELM 的输出为:

$$y(x) = \begin{bmatrix} K_{mix}(x, x_1) \\ \vdots \\ K_{mix}(x, x_n) \end{bmatrix} \left( \frac{E}{C} + K_{ELM} \right)^{-1} Y \quad (34)$$

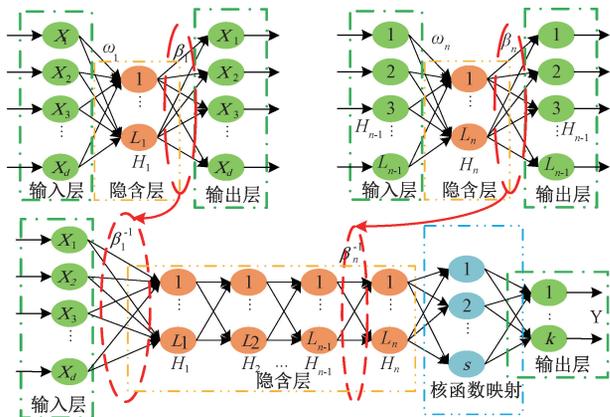


图 5 DHKELM 结构图

Fig. 5 DHKELM structure diagram

光伏阵列故障数据表现出非线性和较低的规律性,而 DHKELM 能够通过 ELM-AE 深度挖掘进行非线性数

据的有效学习,通过混合核函数实现数据映射到高维,有效提高了模型分类的准确性。为进一步提高模型的精度和稳定性,本文利用 IGJO 对 DHKELM 模型各隐含层节点数、ELM-AE 的正则化参数、惩罚因子、核函数权重  $w$ 、RBF 核函数的参数  $\sigma$  以及多项式核函数的参数  $c$  和  $d$  进行优化。

## 4 IGJO-DHKELM 诊断模型

通过光伏阵列正常、单一故障以及复合故障的特性分析,明确了光伏阵列故障诊断过程是一个涉及非线性及高度复杂性的问题,为了得到更加精确的故障诊断结果,搭建了基于 IGJO-DHKELM 的光伏阵列故障诊断模型,其诊断流程如图 6 所示。

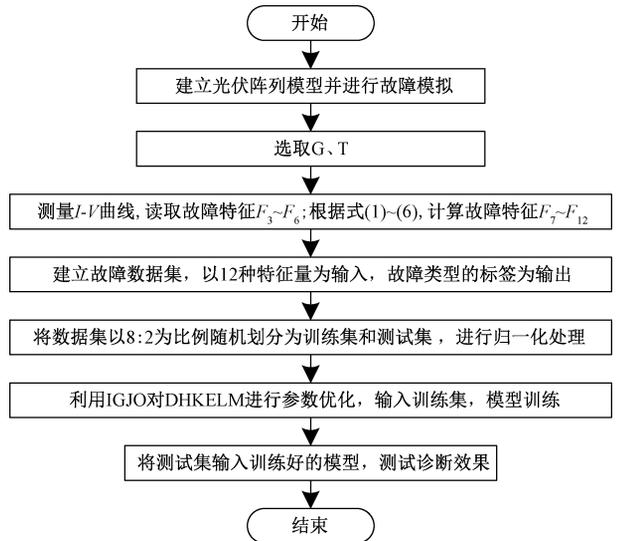


图 6 光伏阵列故障诊断流程

Fig. 6 Troubleshooting process of photovoltaic array

## 5 仿真与对比分析

### 5.1 光伏阵列故障数据采集

基于搭建  $6 \times 4$  的光伏阵列模型,选取 12 种故障类型作为研究对象,如表 2 所示。在进行光伏阵列仿真实验时,设置光伏阵列具体工况范围为:太阳辐照度  $300 \sim 1000 \text{ W/m}^2$ ,步长  $20 \text{ W/m}^2$ ;温度  $15 \text{ }^\circ\text{C} \sim 45 \text{ }^\circ\text{C}$ ,步长  $2 \text{ }^\circ\text{C}$ 。对每一种工况进行故障模拟并通过前面选取的故障特征量进行数据采集,共记采集数据  $12 \times 576 = 6912$  组,按  $8:2$  的比例随机分配训练集和测试集。

### 5.2 不同诊断模型性能对比

为了验证本文所提取的 12 维特征和 DHKELM 模型的优越性和有效性,选取传统的四参数 ( $I_{sc}$ 、 $U_{oc}$ 、 $I_m$ 、 $U_m$ ) 作为 4 维特征,传统的四参数和填充因子作为 5 维特征,

并使用反向传播神经网络 (back propagation neural network, BPNN)、支持向量机 (support vector machine, SVM)、ELM、KELM 等 4 种常见的机器学习模型作对比。将不同数据集分别输入到不同模型中,进行 10 次实验,取平均准确率,其结果如表 5 所示。

表 5 不同模型的平均准确率对比

Table 5 Comparison of average accuracy of different models %

模型名称	4 维特征	5 维特征	12 维特征
BPNN	57.17	62.99	<b>72.94</b>
SVM	52.62	68.23	<b>76.78</b>
ELM	64.21	68.33	<b>77.09</b>
KELM	68.34	71.27	<b>77.64</b>
DHKELM	<b>72.36</b>	<b>75.11</b>	<b>84.90</b>

由表 5 可知,12 维特征的准确率在使用 BP、SVM、ELM、KELM、DHKELM 模型上均是最高,表明本文所提出 12 维故障特征量的有效性;使用不同维度的特征通过 DHKELM 模型进行诊断的准确率均高于其他模型,表明 DHKELM 模型相比于其他模型的诊断性能较好。

5.3 不同算法优化 DHKELM 诊断性能对比

为了验证本研究提出模型的有效性,1 382 组测试数据分别输入到经过训练数据训练好的 DHKELM、GWO-DHKELM、WOA-DHKELM、SSA-DHKELM、GJO-DHKELM 和 IGJO-DHKELM 模型中进行诊断分类,分别设置算法的最大迭代次数和种群规模为 20 和 10。其结果如图 7~12 所示,准确率如图 13 所示。

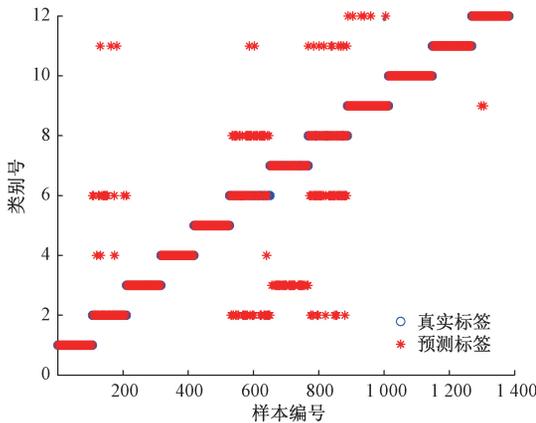


图 7 DHKELM 分类的结果

Fig. 7 The result of DHKELM classification

从图 7~12 可以看出,在这 6 种故障诊断模型中, DHKELM 模型准确率最低,其诊断结果并不理想,对  $A_6$  运行状态极易造成误诊,对  $A_7$  和  $A_8$  运行状态较易造成误诊,在  $A_2$ 、 $A_9$  和  $A_{12}$  运行状态下误诊率较低。从图 8~11 均可看出,通过加入 GWO、WOA、SSA、GJO 算法优化

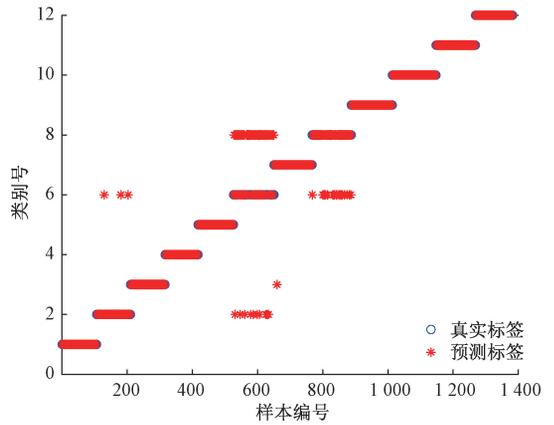


图 8 GWO-DHKELM 分类的结果

Fig. 8 The result of GWO-DHKELM classification

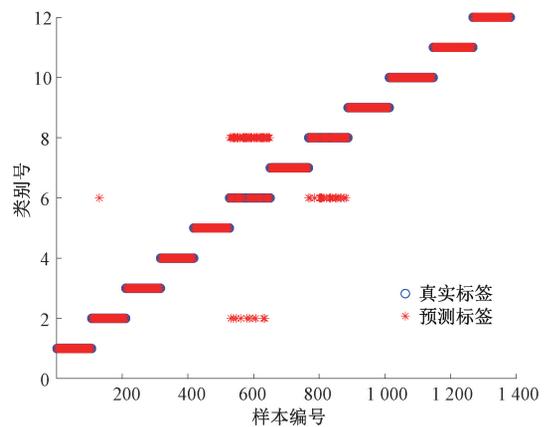


图 9 WOA-DHKELM 分类的结果

Fig. 9 The results of WOA-DHKELM classification

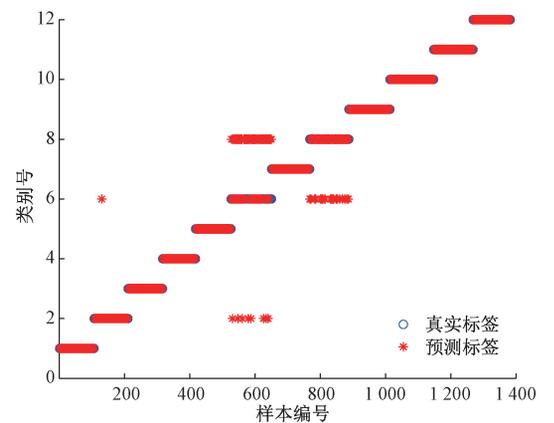


图 10 SSA-DHKELM 分类的结果

Fig. 10 The results of SSA-DHKELM classification

DHKELM 参数后的故障诊断准确率显著提高,特别是使用 GJO 优化参数后的故障诊断准确率提升尤为显著,然而,对于  $A_6$  和  $A_8$  这两种工作状态仍存在较高的误判风

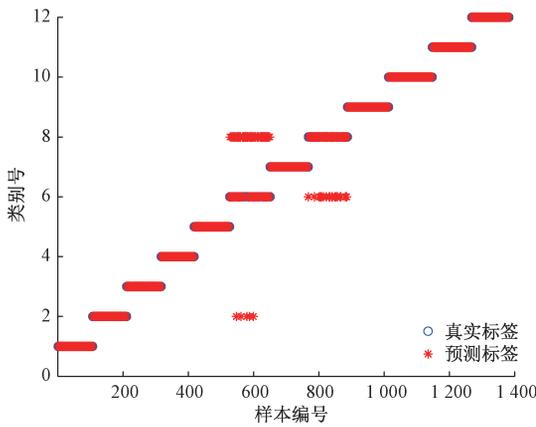


图 11 GJO-DHKELM 分类的结果

Fig. 11 The results of GJO-DHKELM classification

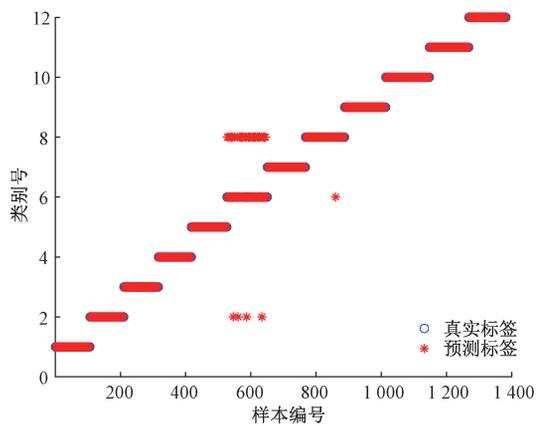


图 12 IGJO-DHKELM 分类的结果

Fig. 12 The results of IGJO-DHKELM classification

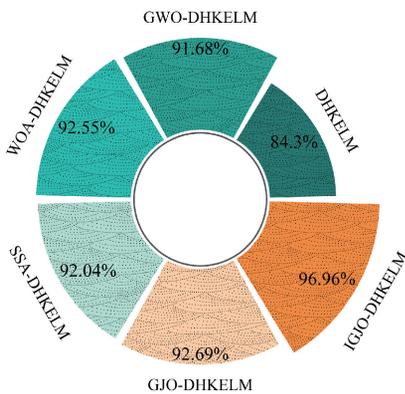


图 13 分类诊断准确率

Fig. 13 Accuracy rate of classification diagnosis

模型均表现出 90% 以上的准确率。具体而言, DHKELM、GWO-DHKELM、WOA-DHKELM、SSA-DHKELM、GJO-DHKELM 及 IGJO-DHKELM 的故障诊断准确率分别是 84.30%、91.68%、92.55%、92.04%、92.69% 和 96.96%。综上, 本文所提的基于 IGJO-DHKELM 故障诊断模型对光伏阵列的故障有较好的诊断效果, 其故障诊断的整体准确率达到到了较为理想的水平。

## 6 结 论

针对光伏阵列故障难以被高效准确地诊断与分类的问题, 提出一种基于改进金豺算法优化深度混合核极限学习机的光伏阵列故障诊断方法。该方法采用光伏阵列的输出特性曲线提取 12 维故障特征量, 对于故障诊断准确率有较好的结果; 通过引入透镜成像方向学习策略、正弦策略和自适应 T 分布扰动策略提高 GJO 的收敛性能和全局寻优能力, 并通过 IGJO 对 DHKELM 的初始化参数进行优化, 建立 IGJO-DHKELM 故障诊断模型。仿真结果证明 IGJO-DHKELM 相比于 DHKELM、GWO-DHKELM、WOA-DHKELM、SSA-DHKELM 和 GJO-DHKELM 等模型, 具有更高的故障诊断准确率, 对光伏阵列的故障进行有效诊断。下一步将考虑不同故障程度进行深入研究, 设计一种更高效的故障诊断方法。

## 参考文献

[ 1 ] 肖先勇, 郑子萱. “双碳”目标下新能源为主体的新型电力系统: 贡献、关键技术与挑战 [ J ]. 工程科学与技术, 2022, 54(1): 47-59.  
XIAO X Y, ZHENG Z X. New power systems dominated by renewable energy towards the goal of emission peak & carbon neutrality: Contribution, key techniques, and challenges [ J ]. Advanced Engineering Sciences, 2022, 54(1): 47-59.

[ 2 ] 彭雅兰, 李志刚. 太阳能光伏阵列在线故障诊断方法综述 [ J ]. 电器与能效管理技术, 2019, (11): 1-7.  
PENG Y L, LI ZH G. A review on online fault diagnosis method for PV arrays [ J ]. Electrical & Energy Management Technology, 2019, (11): 1-7.

[ 3 ] 张晓娜, 高德东, 刘海雄, 等. 一种新型光伏阵列多传感器故障检测定位方法 [ J ]. 可再生能源, 2016, 34(2): 166-172.  
ZHANG X N, GAO D D, LIU H X, et al. A novel method for multi-sensor fault detection and positioning of photovoltaic array [ J ]. Renewable Energy Resources, 2016, 34(2): 166-172.

[ 4 ] ALI M H, RABHI A, EL HAJJAJI A, et al. Real time fault detection in photovoltaic systems [ J ]. Energy Procedia, 2017, 111: 914-923.

险。由图 12 可看出, 通过 IGJO 优化 DHKELM 参数后的故障诊断效果最好, 大大降低了  $A_6$  和  $A_8$  运行状态的误诊率, 使得各类故障的准确率都达到了较好的水准, 优于其他故障诊断模型。从图 13 可知, 5 个不同的故障诊断

- [ 5 ] VERGURA S. Correct settings of a joint unmanned aerial vehicle and infrared camera system for the detection of faulty photovoltaic modules [ J ]. IEEE Journal of Photovoltaics, 2021, 11(1): 124-130.
- [ 6 ] 谢林森, 朱文忠, 谢康康, 等. 基于改进 YOLOv5s 的光伏电池 EL 缺陷图像检测模型 [ J ]. 国外电子测量技术, 2023, 42(6): 93-102.
- XIE L S, ZHU W ZH, XIE K K, et al. Improved YOLOv5s-based image detection model for EL defects in photovoltaic cells [ J ]. Foreign Electronic Measurement Technology, 2023, 42(6): 93-102.
- [ 7 ] 刘行行, 帕孜来·马合木提, 程志江, 等. 基于 XGBoost 的光伏阵列故障诊断方法研究 [ J ]. 电子测量技术, 2023, 46(12): 8-14.
- LIU H H, PAZILAI · M, CHENG ZH J, et al. Research on fault diagnosis method of photovoltaic array based on extreme gradient boosting [ J ]. Electronic Measurement Technology, 2023, 46(12): 8-14.
- [ 8 ] 邢燕好, 于昊, 张佳, 等. 基于粒子群参数优化的 O-VMD 数据处理方法研究 [ J ]. 仪器仪表学报, 2023, 44(4): 304-313.
- XING Y H, YU H, ZHANG J, et al. Research on the O-VMD thickness measurement data processing method based on particle swarm optimization [ J ]. Chinese Journal of Scientific Instrument, 2023, 44 ( 4 ): 304-313.
- [ 9 ] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势 [ J ]. 计算机学报, 2019, 42(7): 1640-1670.
- XU R, LIANG X, QI J SH, et al. Advances and trends in extreme learning machine [ J ]. Chinese Journal of Computers, 2019, 42(7): 1640-1670.
- [ 10 ] 钱亮, 黄伟, 杨建卫. 基于 HHO-ELM 的光伏阵列故障诊断方法研究 [ J ]. 电源技术, 2024, 48(2): 345-350.
- QIAN L, HUANG W, YANG J W. Research on fault diagnosis method of photovoltaic array based on HHO-ELM [ J ]. Chinese Journal of Power Sources, 2024, 48(2): 345-350.
- [ 11 ] 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 L ZH, QIN T, LONG D Y, et al. Fault diagnosis of PV array based on TGBA optimized kernel extreme learning machine [ J ]. Laser Journal, 2021, 42(12): 140-148.
- [ 12 ] 李斌, 郭自强, 高鹏. 改进北方苍鹰算法在光伏阵列中应用研究 [ J ]. 电子测量与仪器学报, 2023, 37(7): 131-139.
- LI B, GUO Z Q, GAO P. Application of improved northern goshawk optimization algorithm in photovoltaic array [ J ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 131-139.
- [ 13 ] 贺全玲, 魏秀业, 赵峰, 等. 基于 IEWT-DELM 的行星齿轮箱故障诊断 [ J ]. 电子测量技术, 2023, 46(3): 190-196.
- HE Q L, WEI X Y, ZHAO F, et al. Planetary gearbox fault diagnosis based on IEWT-DELM [ J ]. Electronic Measurement Technology, 2023, 46(3): 190-196.
- [ 14 ] 聂新华, 秦玉峰, 李尚聰. 基于 BO-DKELM 的滚动轴承故障诊断 [ J ]. 计算机测量与控制, 2024, 32(4): 8-14.
- NIE X H, QIN Y F, LI SH C. Rolling bearing fault diagnosis based on BO-DKELM [ J ]. Computer Measurement & Control, 2024, 32(4): 8-14.
- [ 15 ] 李保丰, 卢文科, 左锋. 利用 GWO-LSSVM 算法对光纤压力传感器进行温度补偿 [ J ]. 电子测量与仪器学报, 2023, 37(5): 143-150.
- LI B F, LU W K, ZUO F. Temperature compensation of optical fiber pressure sensor based on GWO-LSSVM [ J ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 143-150.
- [ 16 ] 关燕鹏, 李子鸣, 贾新春. 基于多维度变异学习与收敛归优的鲸鱼优化算法 [ J ]. 计算机应用研究, 2023, 40(9): 2674-2680.
- GUAN Y P, LI Z M, JIA X CH. Whale optimization algorithm based on multi-dimensional variation learning and distributed optimization [ J ]. Application Research of Computers, 2023, 40(9): 2674-2680.
- [ 17 ] 武文栋, 施保华, 郑传良等. 基于 KPCA-ISSA-KELM 的光伏阵列故障诊断方法 [ J ]. 智慧电力, 2022, 50(11): 69-76.
- WU W D, SHI B H, ZHENG CH L, et al. Fault diagnosis method of PV array based on KPCA-ISSA-KELM [ J ]. Smart Power, 2022, 50(11): 69-76.
- [ 18 ] CHOPRA N, ANSARI M M. Golden jackal optimization: A novel nature-inspired optimizer for engineering applications [ J ]. Expert Systems With Applications, 2022, 198: 116924. DOI: 10.1016/j.eswa.2022.116924.
- [ 19 ] 陈功, 曾国辉, 黄勃, 等. 融合互利共生和透镜成像学习的 HHO 算法 [ J ]. 计算机工程与应用, 2022, 58(10): 76-86.
- CHEN G, ZENG G H, HUANG B, et al. HHO algorithm combining mutualism and lens imaging learning [ J ]. Computer Engineering and Applications, 2022, 58(10): 76-86.
- [ 20 ] 黄学雨, 罗华. 融合正余弦策略的算术优化算法 [ J ]. 计算机工程与科学, 2023, 45(7): 1320-1330.

- HUANG X Y, LUO H. An arithmetic optimization algorithm integrating sine-cosine strategy [J]. *Computer Engineering & Science*, 2023, 45(7): 1320-1330.
- [21] 张伟康, 刘升. 自适应 t 分布与黄金正弦改进的麻雀搜索算法及其应用[J]. *微电子学与计算机*, 2022, 39(3): 17-24.
- ZHANG W K, LIU SH. Improved sparrow search algorithm based on adaptive t-distribution and golden sine and its application [J]. *Microelectronics & Computer*, 2022, 39(3): 17-24.
- [22] 顾崇寅, 徐潇源, 王梦圆, 等. 基于 CatBoost 算法的光伏阵列故障诊断方法[J]. *电力系统自动化*, 2023, 47(2): 105-114.
- GU CH Y, XU X Y, WANG M Y, et al. Catboost algorithm based fault diagnosis method for photovoltaic arrays [J]. *Automation of Electric Power Systems*, 2023, 47(2): 105-114.
- [23] 李斌, 高鹏, 郭自强. 改进蜣螂算法优化 LSTM 的光伏阵列故障诊断[J]. *电力系统及其自动化学报*, 2024, 36(8): 70-78.
- LI B, GAO P, GUO Z Q. Improved dung beetle optimizer to optimize LSTM for photovoltaic array fault diagnosis [J]. *Proceedings of the CSU-EPSA*, 2024, 36(8): 70-78.
- [24] HE Z X, CHU P P, LI CH X, et al. Compound fault diagnosis for photovoltaic arrays based on multi-label learning considering multiple faults coupling[J]. *Energy Conversion and Management*, 2023, 279: 116742.
- [25] 吴建波, 王春艳, 洪华军, 等. 基于极限学习机的船舶柴油机故障诊断[J]. *计算机工程与应用*, 2019, 55(15): 147-152.
- WU J B, WANG CH Y, HONG H J, et al. Fault diagnosis of marine diesel engine based on extreme learning machine [J]. *Computer Engineering and Applications*, 2019, 55(15): 147-152.
- [26] 马卓然. 基于数据驱动的光伏组件故障诊断研究[D]. 北京: 华北电力大学, 2023.
- MA ZH R. Research on photovoltaic module fault diagnosis based on data driven [D]. Bei Jing: North China Electric Power University, 2023.
- [27] 商立群, 侯亚东, 黄辰浩, 等. 基于 IDOA-DHKELM 的变压器故障诊断[J]. *高电压技术*, 2023, 49(11): 4726-4735.
- SHANG L Q, HOU Y D, HUANG CH H, et al. Transformer fault diagnosis based on IDOA-DHKELM [J]. *High Voltage Engineering*, 2023, 49(11): 4726-4735.

### 作者简介



张彼德, 1996 年于河南科技大学获得学士学位, 1999 年于重庆大学获得硕士学位, 2002 年于重庆大学获得博士学位, 现为西华大学教授, 主要研究方向为电气设备在线监测及故障诊断、电力系统过电压分析及抑制等。

E-mail: fyhzzx2015@sina.com

**Zhang Bide** received his B. Sc. degree from Henan University of Science and Technology in 1996, M. Sc. degree from Chongqing University in 1999 and Ph. D. degree from Chongqing University in 2002, respectively. Now he is a professor in Xihua University. His main research interests include online monitoring and fault diagnosis of electrical equipment and overvoltage analysis and suppression of power system, etc.



陈广(通信作者), 2021 年于攀枝花学院获得学士学位, 现为西华大学硕士研究生, 主要研究方向为光伏阵列的故障诊断。

E-mail: chenguang@stu.xhu.edu.cn

**Chen Guang** (Corresponding author) received his B. Sc. degree from Panzhihua College in 2021. Now he is a M. Sc. candidate at Xihua University. His main research interests include fault diagnosis of photovoltaic arrays.