

DOI: 10.13382/j.jemi.B2306388

改进北方苍鹰算法在光伏阵列中应用研究*

李斌 郭自强 高鹏

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要:针对北方苍鹰优化算法(NGO)存在收敛精度低和易陷入局部最优等问题,提出一种改进北方苍鹰算法(INGO),并应用于光伏阵列故障诊断。首先,利用 Circle 映射、自适应权重因子和 Levy 飞行策略改进了北方苍鹰优化算法,结合高斯检测机制和混合核极限学习机(HKELM)搭建 INGO-HKELM 故障诊断模型。其次,将 INGO 算法与 NGO、粒子群算法(PSO)、鲸鱼算法(WOA)在测试函数上进行比较,表明在寻优能力、稳定性等方面具有优越性。然后,分析不同运行状态下光伏阵列运行特征,提出一种 5 维故障特征向量,作为数据的输入。最后,将 4 种算法分别对 HKELM 的核参数进行优化并实现故障分类。结果表明,所提方法能够准确地检测出光伏组件发生的异常状态,INGO-HKELM 模型准确率达到 93.74%,验证了所提算法的有效性和可行性。

关键词:改进北方苍鹰算法;光伏阵列;故障诊断;混合核极限学习机

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

Application of improved northern goshawk optimization algorithm in photovoltaic array

Li Bin Guo Ziqiang Gao Peng

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Aiming at the problems of the northern goshawk optimization algorithm (NGO), such as low convergence accuracy and easy to fall into local optimum, an improved northern goshawk optimization algorithm (INGO) is proposed and applied to the fault diagnosis of photovoltaic array. Firstly, circle mapping, adaptive weight factor and Levy flight strategy are used to improve the INGO. Combined with Gaussian detection mechanism and hybrid kernel extreme learning machine (HKELM), the INGO-HKELM fault diagnosis model is built. Secondly, the INGO algorithm is compared with the NGO, the particle swarm optimization algorithm (PSO), and the whale optimization algorithm (WOA) on the test functions, which shows that it has advantages in optimization ability and stability. Then, the operating characteristics of photovoltaic arrays under different operating states are analyzed, and a 5-D fault feature vector is proposed as the input of data. Finally, the four algorithms are used to optimize the kernel parameters of HKELM and achieve fault classification. The results show that the proposed method can accurately detect abnormal states of photovoltaic modules, and the accuracy of INGO-HKELM model reaches 93.74%, which verifies the effectiveness and feasibility of the proposed algorithm.

Keywords: improved northern goshawk optimization; photovoltaic array; fault diagnosis; hybrid kernel extreme learning machine

0 引言

随着生态环境和气候环境的改变,光伏发电将成为未来的主导新能源,它具有无污染、零排放、取之不尽、用之不竭等优势^[1]。光伏阵列是光伏发电中较为核心的组

成部分,也是光伏发电系统中的源头。由于长期处于相对苛刻的环境中工作,很难避免触发阵列故障,光伏阵列的输出功率将被减小,严重时酿成大火、设备损毁及其他重大恶性事故。因此,有效识别光伏阵列的故障变得尤为重要。

针对光伏阵列故障诊断的问题,国内外学者提供了

许多技术^[2-6]。由于传统的光伏阵列故障诊断技术存在一定的弊端,于是学者们将智能故障诊断方法引入到光伏阵列中,也称人工智能算法。人工智能算法不需要额外的传感器或红外测试仪,也不依赖于数学模型,因此近几年得到了快速的发展,变得日益成熟。根据极限学习机(extreme learning machine, ELM)的性能和特点^[7],研究学者开始把 ELM 应用到故障的诊断。文献[8]提出基于萤火虫扰动麻雀搜索算法的故障诊断策略,解决了 ELM 实现复杂和收敛速度慢的问题。因极限学习机阈值和权值的随机波动,学者们建议把核函数与 ELM 结合起来,形成核极限学习机(kernel extreme learning machine, KELM)。文献[9]提出了由径向基函数(radial basis function, RBF)形成的 KELM 模型,通过改进的粒子群算法(particle swarm optimization, PSO)改善了 RBF 函数局限性的缺陷。文献[10]提出了由高斯核函数(Gaussian kernel function)形成的 KELM 模型,提高了模型的泛化能力,提升了故障识别率。由于核函数本身所具有的缺陷,学者提出将不同类型的核函数融合为混合核函数,避免了各自的缺陷。文献[11]将多项式(polynomial, Poly)核函数与 RBF 函数融合成一种新型混合核函数,将其应用于电路故障的诊断。

基于上述研究,本文提出一种改进北方苍鹰算法(improved northern goshawk optimization, INGO)优化混合核极限学习机(hybrid kernel extreme learning machine, HKELM)进行光伏阵列故障诊断。首先,通过改进北方苍鹰算法解决了混合核函数参数较多的问题。然后,将 INGO 算法与传统的北方苍鹰优化算法(northern goshawk optimization, NGO)、PSO、鲸鱼算法(whale optimization algorithm, WOA)在测试函上进行仿真实验,验证了本文改进北方苍鹰优化算法具有良好的收敛性与稳定性。最后,将四种算法与 HKELM 模型相结合,分别应用于光伏阵列的故障诊断,进一步验证改进算法的优越性。

1 改进北方苍鹰算法优化 HKELM

1.1 北方苍鹰优化算法

NGO 是于 2021 年提出的一种基于种群的优化算法^[12]。该算法主要包括猎物识别阶段、追击和逃逸阶段,苍鹰在每个阶段的位置,如式(1)和(2)所示。

1) 猎物识别阶段

$$x_{i,j}^{new,P1} = \begin{cases} x_{i,j} + r(p_{i,j} - Ex_{i,j}), & F_{p_i} < F_i \\ x_{i,j} + r(x_{i,j} - p_{i,j}), & F_{p_i} \geq F_i \end{cases} \quad (1)$$

式中: $x_{i,j}^{new,P1}$ 为第*i*只北方苍鹰在第1个狩猎阶段中第*j*维度的位置; $P1$ 为第1个狩猎阶段;参数*r*和参数*E*均为随机参数; F_{p_i} 为目标函数值。其中,*r*是属于 $[0,1]$ 之

间的随机数;*E*的数值为1或2。

2) 追击和逃逸阶段

$$x_{i,j}^{new,P2} = x_{i,j} + R(2r - 1)x_{i,j} \quad (2)$$

式中: $x_{i,j}^{new,P2}$ 为第*i*只北方苍鹰在第2个狩猎阶段中第*j*维度的位置; $P2$ 为第2个狩猎阶段;*R*为攻击半径。

NGO 算法的特点是性能良好、收敛精度低、易陷入局部最优。于是,需要对该算法进行改进,提高算法的性能。

1.2 改进北方苍鹰算法

1) Circle 映射的种群初始化

NGO 算法初始化群体时,采用随机生成方法,这一途径将使 NGO 种群的分布不均,后期的迭代寻优也会有不利的影响。根据混沌映射的特点^[13],可以利用混沌序列来初始化 NGO 个体的位置,避免算法陷入局部极值。本文采用 Circle 混沌映射进行种群初始化,它的原理是以参考文献[14]为基础。

2) 自适应权重

当 NGO 算法处于迭代后期的局部开发过程中,个体向当前最优解收敛的途径为直接跳过当前最优位置,多了个盲目跟风,致使 NGO 极易陷入局部最优。本文通过引入一个参数—密度因子来调节这种盲目性。由式(3)可知,迭代次数与密度因子是负相关的关系。密度因子太小,会造成个体信息丢失,由此造成种群多样性下降。同时,当迭代过程中出现较大规模数据集时会降低计算效率。为此,文中提出一种自适应反馈调节因子来改进算法。在 NGO 算法的第一阶段引入自适应惯性权重公式如下:

$$w = \begin{cases} w_{\min} - (w_{\max} - w_{\min}) \times \frac{f - f_{\min}}{f_{avg} - f_{\min}}, & f \leq f_{avg} \\ w_{\max}, & \text{其他} \end{cases} \quad (3)$$

式中:*w*为惯性权重; w_{\max} 和 w_{\min} 分别为最大值和最小值,本文分别设置为0.9、0.4;*f*为适应度值; f_{\min} 为最差适应度值; f_{avg} 为平均适应度值。

权重*w*的引入,使 NGO 在第1阶段位置更新公式由式(1)变为:

$$x_{i,j}^{new,P1} = \begin{cases} x_{i,j} + r \times w(p_{i,j} - Ex_{i,j}), & F_{p_i} < F_i \\ x_{i,j} + r \times w(x_{i,j} - p_{i,j}), & F_{p_i} \geq F_i \end{cases} \quad (4)$$

3) Levy 飞行

Levy 飞行是用于模拟动物觅食的随机游走过程。针对随机搜索的问题,很多学者结合了这种策略来优化算法,从而得到更好的模型^[15-16]。本文在 NGO 算法的第2阶段,采用 Levy 飞行来避免种群陷入局部最优。

该策略的步长数学表达式为:

$$Levy(\beta) = \frac{\mu}{|\nu|^{\frac{1}{\beta}}} \quad (5)$$

式中: $Levy(\beta)$ 为飞行的步长;参数 β 通常为 1.5; μ 、 ν 均为正态分布。

$$\begin{cases} \mu \sim N(0, \sigma_\mu^2) \\ \nu \sim N(0, \sigma_\nu^2) \end{cases} \quad (6)$$

Levy 飞行的引入,使 NGO 在第 2 阶段位置更新公式由式(2)变为:

$$x_{i,j}^{new,P2} = x_{i,j} + R(2r - 1)x_{i,j} + 0.2Levy(\beta) \quad (7)$$

4) 高斯检测机制

北方苍鹰在第 2 阶段结束后,该机制是对个体的所在位置进行变异,得到一个新的位置,检测前后两个位置的适应度。由式(8)和(9)可知,选取适应度较小的值来更新个体位置,其目的是提高算法跳出局部最优的能力^[17]。此机制的数学公式如下:

$$x_m = x_{i,j}^{new,P2} + x_{i,j}^{new,P2} \times N(0, 1) \quad (8)$$

$$x_{i,j}^{new} = \begin{cases} x_m, f(x_m) < f(x_{i,j}^{new,P2}) \\ x_{i,j}^{new,P2}, f(x_m) > f(x_{i,j}^{new,P2}) \end{cases} \quad (9)$$

式中: $N(0, 1)$ 为 0~1 之间的随机数; x_m 为种群变异后的位置。

1.3 核极限学习机

在进行权重计算时 ELM 仅需要计算隐藏层与输出层的值,这导致 ELM 存在不稳定性和鲁棒性差,但避免了大量的计算,提高了训练速度。于是,引入了核函数,形成了 KELM。

根据文献[18]可以得到 KELM 的模型输出表示为:

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\Omega + \frac{I}{C} \right)^{-1} T \quad (10)$$

式中: Ω 为核矩阵; I 为单位矩阵; C 为惩罚系数; T 为目标输出矩阵。

KELM 模型不仅保留了 ELM 模型的优势,还提高了模型的泛化能力和稳定性。

1.4 混合核极限学习机

学者通常把核函数分为局部型核函数和全局型核函数。单一核函数与极限学习机融合存在一定的局限性,于是学者将不同类别的核函数混合,使模型具有较强的局部搜索能力和全局搜索能力^[19]。本文将 Poly 核函数和 RBF 与 ELM 相融合构成 HKELM 模型,从而更好地诊断出故障类型和选取特征值之间的非线性关系。

混合核函数的计算公式如下:

$$K_{HKELM}(x_i, x_j) = \lambda K_{RBF} + (1 - \lambda) K_{Poly} = \lambda \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) + (1 - \lambda)(x, x_i + c)^d \quad (11)$$

式中: σ 为 RBF 参数; c, d 为 Poly 参数; λ 为权重系数, $\lambda \in (0, 1)$ 。

从混合核函数计算公式及核极限学习机输出表达式得知, HKELM 模型可变参数很多。为了避免手工选取参数会使诊断效率减小、回归精度难以达到最优值等弊端,采用 NGO 对 HKELM 模型的惩罚系数 C 、核参数 (σ 、 c 和 d) 以及权重系数 λ 进行优化。

1.5 INGO-HKELM 模型建立

本文基于上述研究,提出一种新型光伏阵列故障诊断模型——基于 INGO 优化 HKELM 的故障诊断模型。该模型的具体流程如图 1 所示。

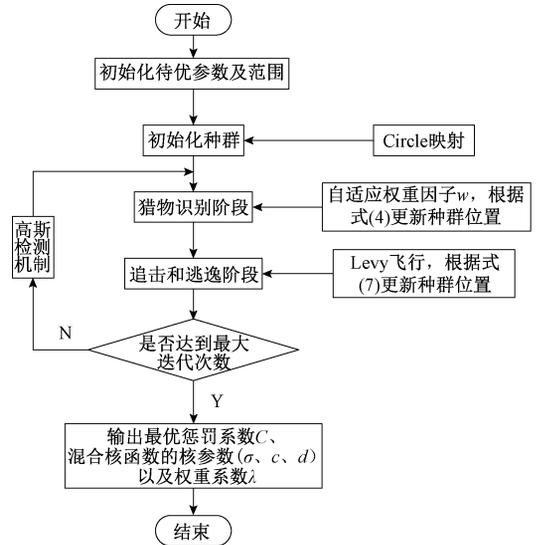


图 1 INGO-HKELM 流程

Fig. 1 Flow chart of INGO-HKELM

2 INGO 算法的性能测试

将本文的改进算法和 NGO、PSO、WOA 分别进行各个测试函数比较,主要是为了对文中提出改进算法可行性与性能有较好的评估。各种算法主要参数的设置如表 1 所示。

表 1 算法主要参数

Table 1 Main parameters of the algorithm

算法	参数
INGO	惯性权重: $w \in [0.4, 0.9]$
	攻击半径: $R = 0.02 \times (1 - t/Maxiter)$
NGO	攻击半径: $R = 0.02 \times (1 - t/Maxiter)$
PSO	惯性因子: $w = 0.9$
	学习因子: $c_1 = c_2 = 2$
WOA	收敛因子: $a = 2-2t/Maxiter$
	螺旋常数: $b = 1$
	行为选择概率: $p = 0.5$

近几年,学者常用基准测试函数来评价算法。其中,

利用单峰函数对算法开发能力进行评估和利用多峰函数进行搜索能力评估,分别选取两个测试进行评估($F1$ 、 $F2$ 为单峰函数, $F3$ 、 $F4$ 为多峰函数),函数如表 2 所示。对全部算法的迭代次数、种群数量、运行次数和维数进行相同的设定,其值依次为 500 次、30 个、30 次和 30。

表 2 基准测试函数
Table 2 Benchmark test functions

函数	搜索范围	理论值
$F1(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$	0
$F2(x) = \sum_{i=1}^n ([x_i + 0.5]^2)$	$[-100, 100]$	0
$F3(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$	0
$F4(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	$[-32, 32]$	0

适应度的最大值、最小值及平均值体现算法寻优能力及有效性,标准差体现算法稳定性^[20],故求解各测试函数,如表 3 所示。每个测试函数的平均收敛曲线,如图 2 所示。

由表 2~3 可知,当测试函数为 $F1$ 时,只有 INGO 算法的适应度达到理论值;当测试函数为 $F2$ 时,所有算法均没有达到理论值,但 INGO 算法无论适应度还是标准差的值,都有着最优的效果;当测试函数为 $F3$ 时,INGO 和 NGO 算法的适应度达到理论值,证明了北方苍鹰优化算法拥有良好的搜索能力;当测试函数为 $F4$ 时,所有算法均没有达到理论值,INGO 算法的适应度值均不大于其他算法,且适应度的标准差为 0,证明该算法更稳定。

由图 2 可见,4 种算法在同时搜索最优解时,INGO 算法的收敛速度好于其他算法;PSO 算法的适应度值最差,且过早收敛,陷入了局部极值;NGO 算法比 WOA 算法的迭代次数快。其中,图 2(b)、(c)和(d)的效果图最为明显,表明了该算法所采用的位置更新和改进策略,既加速了算法的收敛,还加强了算法最优解的寻找能力。

表 3 测试函数结果对比

Table 3 Comparison of test function results

函数名	指标	INGO	NGO	PSO	WOA
F1	最大值	0	1.5901×10^{-46}	4.197 3	9.5283×10^{-60}
	平均值	0	6.3091×10^{-46}	11.215 8	1.3932×10^{-53}
	最小值	0	2.219×10^{-45}	31.071 6	1.5584×10^{-52}
	标准差	0	4.9066×10^{-46}	7.509	3.8458×10^{-53}
F2	最大值	7.9128×10^{-13}	5.2166×10^{-7}	45.497 1	0.017 708
	平均值	3.1017×10^{-8}	8.9497×10^{-7}	141.728 8	0.077 683
	最小值	1.7451×10^{-7}	2.802×10^{-6}	231.553 3	0.287 52
	标准差	4.2672×10^{-8}	3.9741×10^{-7}	50.664 7	0.061 139
F3	最大值	0	0	167.307 1	0
	平均值	0	0	221.825 2	1.8948×10^{-15}
	最小值	0	0	278.263 6	5.6843×10^{-14}
	标准差	0	0	30.466 3	1.0378×10^{-14}
F4	最大值	8.8818×10^{-16}	4.4409×10^{-15}	6.670 3	8.8818×10^{-16}
	平均值	8.8818×10^{-16}	7.1646×10^{-15}	9.414 9	5.7436×10^{-15}
	最小值	8.8818×10^{-16}	1.5099×10^{-14}	16.118 3	1.5099×10^{-14}
	标准差	0	3.189×10^{-15}	1.949 5	3.4259×10^{-15}

综上所述,INGO 算法的稳定性和寻优能力较好,为光伏阵列故障诊断的应用提供理论依据。

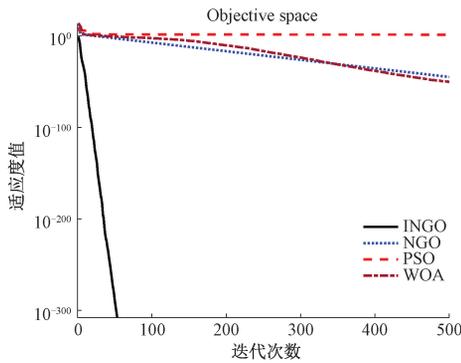
3 光伏阵列

3.1 故障分析

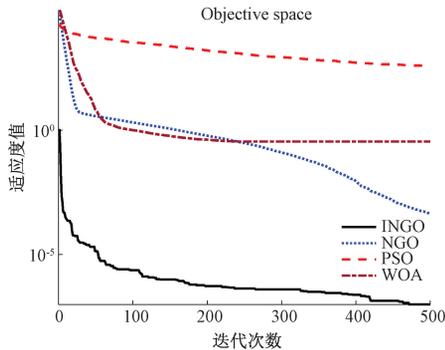
在现实生活中,多个光伏电池串联组合成光伏组件。将光伏电池视为二极管和光生电流源并联^[21],如图 3 所示。

根据光伏阵列的实际运行状态可知,常见的故障有:

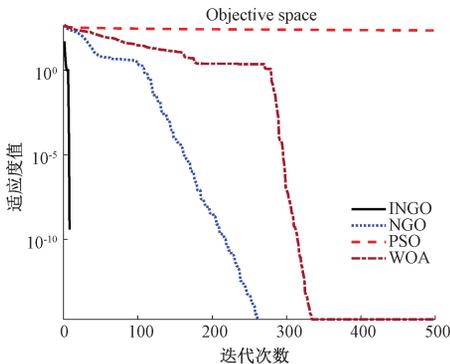
开路、短路、阴影以及线路老化。其中,采用切断邻近光伏组件的导线的方法进行仿真开路故障。采用短接故障光伏组件正负极的方式进行仿真短路故障。采用降低某些光伏组件光照强度的方法进行仿真阴影遮挡故障。通过仿真测试表示,神经网络能够诊断阴影遮挡系数为 0.4~0.7,无法识别其他遮挡系数^[22]。因此,选择遮挡系数 0.4 为轻度阴影,遮挡系数 0.7 为重度阴影。通过在某条支路上增加电阻,可以模拟出老化故障,主要表现为图 1 中串联电阻 R_s 的增加。设置支路增加电阻的阻值 3 Ω 为轻微老化,阻值 10 Ω 为严重老化。



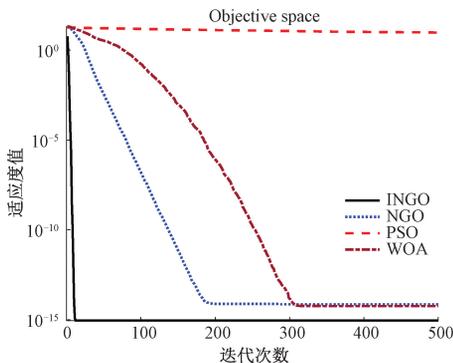
(a) F1函数值收敛曲线
(a) Convergence curve of F1 function values



(b) F2函数值收敛曲线
(b) Convergence curve of F2 function values



(c) F3函数值收敛曲线
(c) Convergence curve of F3 function values



(d) F4函数值收敛曲线
(d) Convergence curve of F4 function values

图2 测试函数平均收敛曲线

Fig. 2 Average convergence curve of test function

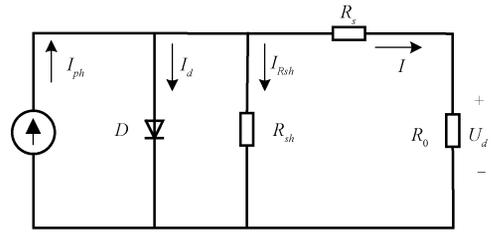


图3 光伏电池电路图

Fig. 3 Circuit diagram of photovoltaic cell

3.2 故障特征提取及数据采集

1) 网络输入与输出节点的确定

本文在 3.1 节中对光伏的故障类型进行了详细的叙述,在此基础上将光伏阵列工作状态细分为 10 类。光伏阵列故障检测模型的输出层,如表 4 所示。本文在标准测试条件 STC(辐照度 1 000 W/m²,温度 25 ℃)下,用 MATLAB 仿真出不同工作状态时的 I-U 曲线和 P-U 曲线,如图 4~5 所示。

表 4 光伏阵列的故障类型

Table 4 Fault types of photovoltaic arrays

标签	故障名称	工作状态
E1	无故障	正常工作
E2	短路 1	1 个组件短路
E3	短路 2	2 个组件短路
E4	开路	1 条支路开路
E5	老化 1	轻微老化
E6	老化 2	严重老化
E7	阴影 1	1 条支路轻度阴影
E8	阴影 2	3 个并联的组件轻度阴影
E9	阴影 3	1 条支路轻度阴影和 1 条支路重度阴影
E10	阴影 4	3 个并联的组件轻度阴影和 3 个并联的组件重度阴影

由图 4 可知,相对于短路电流 I_{sc} ,当光伏阵列的运行状态为 E4、E7 和 E9 时,各自的短路电流有区分且数值低于其他运行状态。相对于开路电压 U_{oc} ,当光伏阵列的运行状态为 E2 和 E3 时,各自的开路电压有区分且数值低于其他运行状态。由图 5 可知,相对于最大功率 P_{mm} ,当运行状态为 E1 和 E5 时,与其他状态有明显区分且数值较高;当光伏阵列的运行状态为 E3、E4 和 E10 时,数值较低。相对于最大功率点电压 U_{mm} ,当光伏阵列运行状态为 E2、E3、E8 和 E10 时,数值较小。填充因子 FF 能够反映光伏电池的输出性能。

分析可知,光伏阵列输出参数的出现在各种状态下会出现一个或者多个明显的变化,故选择 U_{oc} 、 I_{sc} 、 U_{mm} 、 I_{mm} 和填充因子 FF 作为故障的特征参数。

2) 获取样本数据集

本文研究太阳能组件的主要参数为:最大功率点电

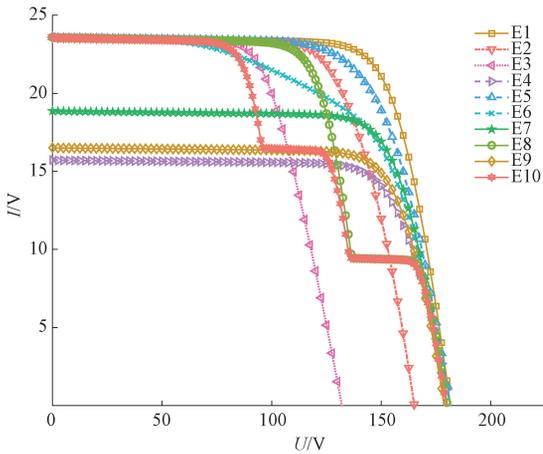


图 4 不同状态下光伏阵列 I-U 曲线

Fig. 4 I-U curves of PV array in different states

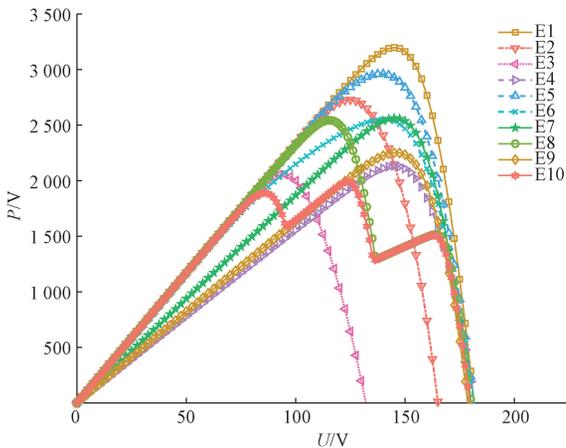


图 5 不同状态下光伏阵列 P-U 曲线

Fig. 5 P-U curves of PV array in different states

流 $I_{mm} = 7.35 \text{ A}$ 、短路电流 $I_{sc} = 7.84 \text{ A}$ 、最大功率点电压 $U_{mm} = 29 \text{ V}$ 、开路电压 $U_{oc} = 36.3 \text{ V}$ 和最大功率 $P_{mm} = 213.15 \text{ W}$ 。在 MATLAB/Simulink 平台搭建 3×5 的光伏阵列模型,即先将 5 个组件串联成支路,后将 3 条支路并联,共计 15 块太阳能组件。光伏阵列进行仿真实验时,组件的辐照度为 $500 \sim 1\,000 \text{ W/m}^2$,步长为 20 W/m^2 ;组件的温度为 $25 \text{ }^\circ\text{C} \sim 45 \text{ }^\circ\text{C}$,步长为 $2 \text{ }^\circ\text{C}$ 。首先,依次对相应的光伏阵列模型进行模拟并收集各状态下相应特征参数值,总共收集了 2 860 组数据。然后,按照 8 : 2 的比例把数据分成训练样本与测试样本。最后,把数据输入到模型中进行光伏阵列故障的分类。

4 仿真结果与分析

为了更好地评估 HKELM 模型对于光伏故障的分类效果,使一定的参数保持不变。其中,最大迭代次数为

20 次,种群规模为 30 个。接着,将数据分别输入 INGO-HKELM,NGO-HKELM,PSO-HKELM 和 WOA-HKELM 模型中进行故障诊断,得到 4 种模型测试样本的结果,如图 6~9 所示,图 10 给出了各模型准确率的径向条形图。

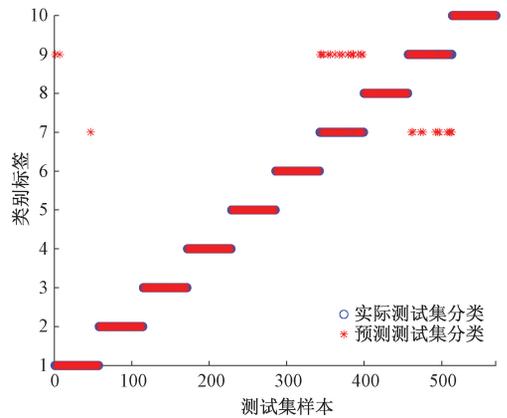


图 6 INGO-HKELM 故障诊断模型的结果

Fig. 6 Results of INGO-HKELM fault diagnosis model

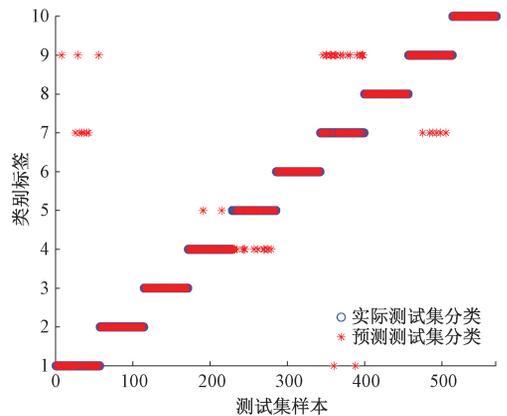


图 7 NGO-HKELM 故障诊断模型的结果

Fig. 7 Results of NGO-HKELM fault diagnosis model

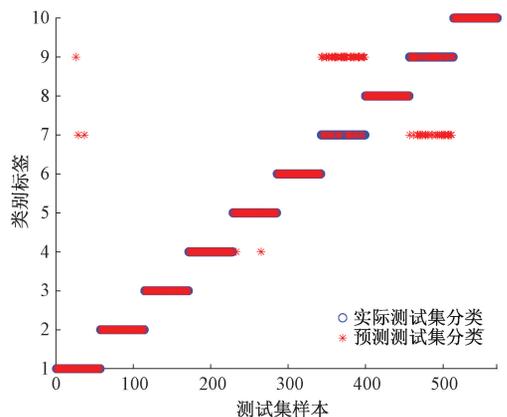


图 8 PSO-HKELM 故障诊断模型的结果

Fig. 8 Results of PSO-HKELM fault diagnosis model

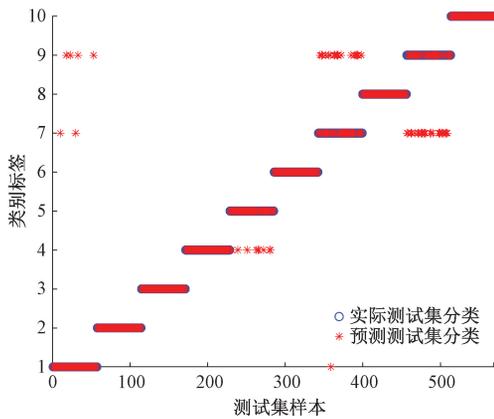


图9 WOA-HKELM故障诊断模型的结果

Fig.9 Results of WOA-HKELM fault diagnosis model

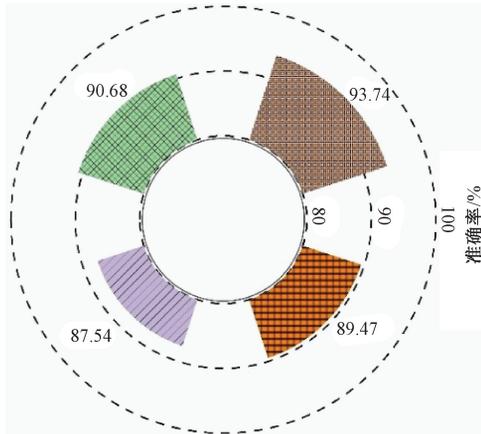


图10 不同模型的诊断准确率

Fig.10 Diagnostic accuracy of different models

由图6~9可知, HKELM模型对光伏阵列运行状态为E7和E9的分辨率较低, 但总体诊断效果较好。由图10可知, 各模型的准确率均在85%以上, INGO-HKELM、NGO-HKELM、PSO-HKELM和WOA-HKELM的故障诊断准确率分别为93.74%、90.68%、87.54%、89.47%。实验表明, 本文的改进算法具有最高的识别率, 能更好解决混合核极限学习机参数选择的问题。

5 结论

本文提出一种采用INGO优化HKELM参数的方法, 解决了光伏阵列不同程度故障类型难以准确诊断的问题。本文得出的主要结论如下:

1) 本文对NGO算法进行了3个方面的改进: 其一, 利用Circle混沌映射初始化种群的位置; 其二, 引入自适应权重因子避免在第1阶段陷入局部最优; 其三, 引入Levy飞行避免在第2阶段陷入局部最优。然后, 通过高

斯检测机制的判断, 构建INGO-HKELM故障诊断模型。解决了HKELM的惩罚系数 C 、混合核函数的核参数(σ 、 c 和 d)以及权重系数 λ 选择困难问题。

2) 在MATLAB/Simulink平台仿真了不同的故障类型, 通过分析I-U曲线和P-U曲线, 选择出 U_{oc} 、 I_{sc} 、 U_{mm} 、 I_{mm} 和填充因子FF作为故障的特征参数, 并将其作为故障诊断模型的输入参数。通过对故障诊断结果的观察, 该5个故障特征向量能很好地分辨各类故障。

3) 在基准测试函数实验上, 将本文提出的INGO算法与传统NGO算法、PSO算法以及WOA算法相比较, 实验表明该算法具有更好的寻优能力和稳定性。通过对4种模型进行故障诊断仿真分析, 结果表明INGO-HKELM模型相比其他3种模型具有更高的准确率。

参考文献

[1] 颜奕, 黄宇, 陈鸣, 等. 基于电容阵列 I-V 测试仪的光伏 STC 曲线拟合研究[J]. 电子测量与仪器学报, 2017, 31(2): 272-279.
YAN Y, HUANG Y, CHEN M, et al. Research on optimal control strategy of VSG in photovoltaic generation based on SOC characteristic boundary condition [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(2): 272-279.

[2] ALSAFASFEH M, ABDEL-QADER I, BAZUIN B, et al. Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision[J]. Energies, 2018, 11(9): 2252.

[3] PEI T, LI L, ZHANG J, et al. Module block fault locating strategy for large-scale photovoltaic arrays[J]. Energy Conversion and Management, 2020, 214: 112898.

[4] CHEN Z, WU L, CHENG S, et al. Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and IV characteristics [J]. Applied Energy, 2017, 204: 912-931.

[5] PEI T, HAO X. A fault detection method for photovoltaic systems based on voltage and current observation and evaluation[J]. Energies, 2019, 12(9): 1712.

[6] DE BENEDETTI M, LEONARDI F, MESSINA F, et al. Anomaly detection and predictive maintenance for photovoltaic systems[J]. Neurocomputing, 2018, 310: 59-68.

[7] 唐圣学, 刁旭东, 陈丽, 等. 光伏发电系统直流串联微弱故障电弧检测方法研究[J]. 仪器仪表学报, 2021, 42(3): 150-160.
TANG SH X, DIAO X D, CHEN L, et al. Study on detection method of weak series DC fault arc in PV power

- generation systems [J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 150-160.
- [8] 赵靖英, 吴晶晶, 张雪辉, 等. 基于萤火虫扰动麻雀搜索算法-极限学习机的光伏阵列故障诊断方法研究[J]. 电网技术, 2023, 47(4): 1612-1625.
- ZHAO J Y, WU J J, ZHANG X H, et al. Research on fault diagnosis method of photovoltaic arrays based on sparrow search algorithm with firefly perturbation-extreme learning machine [J]. Power System Technology, 2023, 47(4): 1612-1625.
- [9] MEI H Z, VORONIN V V, WEI W, et al. Transformer fault diagnosis based on improving kernel-based extreme learning machine [C]. 2018 Eighth International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC). IEEE, 2018: 1669-1674.
- [10] 齐咏生, 单成成, 高胜利, 等. 基于 AEWT-KELM 的风电机组轴承故障诊断策略[J]. 太阳能学报, 2022, 43(8): 281-291.
- QI Y SH, SHAN CH CH, GAO SH L, et al. Fault diagnosis strategy of wind turbines bearing based on AEWT-KELM [J]. Acta Energetica Solaris Sinica, 2022, 43(8): 281-291.
- [11] WANG S, LIU Z, JIA Z, et al. Incipient fault diagnosis of analog circuit with ensemble HKELM based on fused multi-channel and multi-scale features[J]. Engineering Applications of Artificial Intelligence, 2023, 117: 105633.
- [12] DEHGhani M, HUBALOVSKY S, TROJOVSKY P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems [J]. IEEE Access, 2021, 9: 162059-162080.
- [13] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization [J]. Neural Computing and Applications, 2018, 31(8): 4385-4405.
- [14] 徐福强, 邹德旋, 李灿, 等. 引入 Circle 映射和正弦余弦因子的改进粒子群算法[J/OL]. 计算机工程与应用: 1-13 [2023-03-21]. <http://202.199.233.17:8000/rwt/CNKI/http/NNYHGLUDN3WXTLUPMW4A/kcms/detail/11.2127.TP.20230224.1812.016.html>.
- XU F Q, ZOU D X, LI C, et al. Improved particle swarm optimization algorithm with circle mapping and sine cosine factor [J/OL]. Computer Engineering and Applications: 1-13 [2023-03-21]. <http://202.199.233.17:8000/rwt/CNKI/http/NNYHGLUDN3WXTLUPMW4A/kcms/detail/11.2127.TP.20230224.1812.016.html>.
- [15] 赵莹莹, 何怡刚, 杜博伦, 等. 基于 LSSA 优化 DBN 的双有源桥变换器开路故障诊断[J]. 电子测量与仪器学报, 2022, 36(4): 56-64.
- ZHAO Y Y, HE Y G, DU B L, et al. Open circuit fault diagnosis of dual active bridge converter based on LSSA optimized DBN [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(4): 56-64.
- [16] 曹梦龙, 马俊林. 改进蝗虫优化算法在模糊神经网络 PID 控制中的研究 [J]. 电子测量技术, 2022, 45(20): 74-80.
- CAO M L, MA J L. Research on improved grasshopper optimization algorithm PID control of fuzzy neural networks [J]. Electronic Measurement Technology, 2022, 45(20): 74-80.
- [17] 王延峰, 廖荣航, 梁恩豪, 等. 基于围攻机制的改进鲸鱼优化算法[J/OL]. 控制与决策: 1-9 [2023-03-28].
- WANG Y F, LIAO R H, LIANG EN H, et al. Improved whale optimization algorithm based on siege mechanism [J/OL]. Control and Decision: 1-9 [2023-03-28].
- [18] CHEN J, YANG Y, MEI T, et al. Research on fault diagnosis for TCT photovoltaic array based on BA-KELM model [C]. 2019 34rd Youth Academic Annual Conference of Chinese Association of Automation (YAC). IEEE, 2019: 233-238.
- [19] 郭建帅, 崔双喜, 郭建斌, 等. 基于 VMD-SSA-HKELM 的超短期负荷预测[J]. 国外电子测量技术, 2022, 41(6): 105-111.
- GUO J SH, CUI SH X, GUO J B, et al. Ultra-short-term load prediction based on VMD-SSA-HKELM [J]. Foreign Electronic Measurement Technology, 2022, 41(6): 105-111.
- [20] 周娇. 基于图像分割的群智能算法改进研究[D]. 贵阳: 贵州大学, 2021.
- ZHOU J. Research on Improvement of swarm intelligence algorithm based on image segmentation [D]. Guiyang: Guizhou University, 2021.
- [21] 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.
- [22] 何根新, 周俊杰, 周家兴, 等. 基于自适应权重粒子群优化 BP 神经网络的光伏阵列故障诊断方法研究[J]. 电子设计工程, 2021, 29(9): 75-79.

HE G X, ZHOU J J, ZHOU J X, et al. Research on fault diagnosis method of photovoltaic array based on BP neural network with adaptive weight particle swarm optimization [J]. Electronic Design Engineering, 2021, 29(9): 75-79.

作者简介



李斌, 分别在 2003 年、2006 年和 2012 年于辽宁工程技术大学获得学士学位、硕士学位和博士学位。现为辽宁工程技术大学副教授, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。

E-mail: 25992816@qq.com

Li Bin received his B. Sc. degree in 2003, M. Sc. degree in 2006 and Ph. D. degree in 2012 from Liaoning Technical University, respectively. Now he is an associate professor in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



郭自强(通信作者), 2021 年于山西大同大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能电器与智能电网技术。

E-mail: 2286813166@qq.com

Guo Ziqiang (Corresponding author)

received his B. Sc. degree from Shanxi Datong University in 2021. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include intelligent appliances and smart grid technology.



高鹏, 2021 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能电器与智能电网技术。

E-mail: 1563340912@qq.com

Gao Peng received her B. Sc. degree

from Liaoning Technical University in 2021. Now she is a M. Sc. candidate in Liaoning Technical University. Her main research interests include intelligent appliances and smart grid technology.