

DOI:10.19651/j.cnki.emt.2416021

# 自适应多元优化局部放电识别算法研究<sup>\*</sup>

夏金平<sup>1</sup> 高莲<sup>1</sup> 李鹏<sup>1</sup> 陈昌川<sup>2</sup>

(1. 云南大学信息学院 昆明 650091; 2. 重庆邮电大学通信与信息工程学院 重庆 400065)

**摘要:** 局部放电作为电力设备绝缘系统失效的早期主要表现,准确有效识别对检修计划的制定及实施,保障电力系统安全可靠运行具有重要意义。为进一步提高局部放电故障识别准确率,引入了基于多元化结构的过程记忆全局局部交替搜索多模态智能多元优化算法对局部放电故障进行识别,但算法搜索元构建具有随机性及相关参数的设定对实际环境下复杂局部放电故障识别具有较高针对性;针对这些问题,本文提出了自适应多元优化局部放电识别算法,该方法首先对数据样本进行网格划分映射,其次利用网格对象的密度差异性滤除部分稀疏网格数据点,探索高密度区域密度峰值点个数作为局部放电潜在故障类别数,最后通过具有自适应搜索记忆能力的多元优化算法不断全局局部交替搜索实现自动识别局部放电故障。为验证本文算法的有效性,将其应用于高压设备的电晕放电、悬浮放电、气隙放电、沿面放电局部放电数据集以及实际工况下气体绝缘全封闭组合电器绝缘表面局部放电数据集,实验结果表明,该方法平均识别准确率分别比RDB、KPP、SVM-KNN、DPC-DLP、GWOKM、PSO、MOA算法提高了19.53%、13.04%、19.46%、37.18%、7.79%、8.13%、4.19%,说明了本文提出的自适应多元优化局部放电识别算法的有效性,对实际局部放电故障类型识别准确率的提高具有重要意义。

**关键词:** 网格密度;密度峰值;局部放电;多元优化;故障识别

中图分类号: TM835; TN01 文献标识码: A 国家标准学科分类代码: 510.4030

## Adaptive multivariant optimization algorithm for partial discharge recognition

Xia Jinping<sup>1</sup> Gao Lian<sup>1</sup> Li Peng<sup>1</sup> Chen Changchuan<sup>2</sup>

(1. School of Information Science and Technology, Yunnan University, Kunming 650091, China; 2. School of Information and Communication Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** The correct identification of partial discharge (PD) as an early indication of many insulation problems in electrical equipment is crucial for formulating maintenance plans which is an effective way to avoid catastrophic failure as the associated defects are treated at an early stage. The memory-based Multimodal multivariant optimization algorithm(MOA) is applied for PD fault identification based on an iterative global and local search to further improve the accuracy of partial discharge (PD) fault identification. However, the construction of the algorithm's search element has randomness and the setting of related parameters has high pertinence to the identification of complex PD faults in the actual environment. So This article proposes a novel adaptive multivariant optimization algorithm for PD recognition(AMOA). The first step is concerned with the PD data projection into different grids, in which the data may be removed from the data set if it has sparse local density and number of data peak density points are explored as potential PD fault categories if it has high density. After that, the memory-based MOA is applied to identify the PD fault based on an iterative global and local search. With a view to examining the validity of the proposed method, it is applied to the PD datasets of corona discharge, suspension discharge, air gap discharge, discharge along the surface in high-voltage equipment, as well as to the PD datasets of Insulator Surface discharge in GIS under actual operating conditions. The results show that it's average recognition accuracy is 19.53%、13.04%、19.46%、37.18%、7.79%、8.13% and 4.19% higher than that obtained by the RDB, KPP, SVM-KNN, DPC-DLP, GWOKM, PSO, and MOA algorithms, respectively. It could be concluded that the proposed approach offers the advantages of high PD fault recognition for the electrical equipment.

**Keywords:** grid density; density peak; partial discharge; multivariant optimization; fault recognition

## 0 引言

局部放电(partial discharge, PD)现象作为电气设备绝

缘故障的早期表现及重要诱因<sup>[1]</sup>,是造成电力系统运行故障的常见原因之一。通过PD故障类型的有效准确判断可实现故障预警,对进一步定向检修计划的制定及实施提供

理论依据,对保障电力系统安全稳定运行具有重要的意义<sup>[2-3]</sup>。

在电力系统运行现场,相关工程师借助脉冲电流法、特高频法、超声波法等<sup>[4-6]</sup>方法获得 PD 信号后对故障类型进行识别与检测,但检测结果因人而异,无法保障一致性及有效性<sup>[7]</sup>。为进一步提高 PD 检测结果的有效性,研究者们借助支持向量机(support vector machine, SVM)、灰狼算法(grey wolf optimizer, GWO)与神经网络(neural-network model)模型等机器学习方法对 PD 信号进行客观分析提取故障检测相关参数达到故障检测的目的;褚鑫等<sup>[8]</sup>通过 M-ary 算法将各二类分类器的输出作为输入应用于 SVM 达到 PD 类型识别的目的,该方法对油中气隙 PD 识别效果较好,但单核 SVM 结构对其他类型故障识别效果欠佳。宋人杰等<sup>[9]</sup>提出了基于多核 SVM 的 PD 分类方法,通过线性组合多个核学习整合 PD 多类型特征到达故障识别的目的,一定程度提高了故障识别准确性,但算法复杂度较高,所需识别时间较长。文献[10]提出了基于灰狼优化算法变压器 PD 检测方法,通过其较优全局搜索与快速收敛能力在相对较短时间内实现了未知搜索空间数据特征提取及故障有效识别,但对复杂数据集易出现收敛精度不高及泛化能力不强的问题。研究者们<sup>[11-12]</sup>提出了基于神经网络复杂类型 PD 故障识别方法,但实验构建神经网络数据集具有较高针对性,难以自适应应用于实际工况下采集的具有高聚集性、难分性、数据集各簇呈球状且细长以及密度不平衡性等复杂特征 PD 故障数据<sup>[13]</sup>。近年研究者们提出了基于历史的全局与局部交替搜索协同合作的群智能多元优化算法(multivariant optimization algorithm, MOA),该方法基于历史搜索结果对解空间进行细致而全面寻优,已有效应用于 Michalewicz、Langermann 等复杂测试函数<sup>[14]</sup>,同时为 PD 故障检测的动态跟踪与自适应调整提供了有效途径。本文基于 MOA 提出了自适应多元优化局部放电识别算法(adaptive multivariant optimization algorithm for PD recognition, AMOA),该算法首先对数据样本进行网格划分映射,并利用网格对象的密度差异性滤除部分稀疏网格数据点,探索高密度区域密度峰值点个数作为 PD 潜在故障类别数传入 MOA 进行不断全局局部自适应搜索自动识别 PD 故障,从而在有效避免 MOA 算法冗余计算的同时,一定程度提高实际工况 PD 故障检测的可行性。实验将 AMOA 算法应用于高压设备电晕放电、悬浮放电、气隙放电、沿面放电四类典型的 PD 故障数据集以及施加 385 kV 与 375 kV 的电压下气体绝缘全封闭组合电器(gas insulated substation, GIS)绝缘表面 PD 故障数据集的识别,同时与现有基于反向最近邻密度估计的密度聚类算法(a density-based clustering algorithm using reverse nearest neighbor density estimates, RNN-DBSCAN)<sup>[15]</sup>、K 均值聚类++(k-means++, KPP)<sup>[16]</sup>、基于 K 邻近改进的支持向量机(support vector machine based on k-nearest

neighbor, SVM-KNN)<sup>[17]</sup>、基于动态图的标签传播的密度峰值聚类算法(dynamic graph-based label propagation for density peaks clustering, DPC-DLP)<sup>[18]</sup>、基于 K 均值聚类的灰狼优化算法(grey wolf optimizer algorithm with k-means clustering, GWOKM)<sup>[19]</sup>、粒子群优化算法(particle swarm optimization, PSO)<sup>[20]</sup>、多元优化算法(multivariant optimization algorithm, MOA)等先进密度和非密度聚类算法作为基线方法进行了比较,其平均识别准确率分别提高了 19.53%、13.04%、19.46%、37.18%、7.79%、8.13%、4.19%,有效说明 AMOA 算法对 PD 故障数据集的识别能力;为进一步说明该算法的泛化性,将其应用于 UCI 数据集,结果表明此算法对不同类型数据都具有更高的效率与准确性。本文将从算法原理、PD 识别实验与非 PD 识别泛化实验与进行阐述,以全面展示 AMOA 算法的优越性。

## 1 算法原理

### 1.1 多元优化算法

MOA 算法是基于多元化结构的过程记忆全局局部交替搜索多模态智能算法,可对动静条件下聚类问题进行有效解决<sup>[21]</sup>,适合于 PD 故障的有效识别。MOA 算法通过多元化结构存储过程中产生的全局及局部搜索元信息如图 1 所示,以对解空间进行全局与局部搜索,从而逼近全局最优并有效避免搜索陷入局部最优。

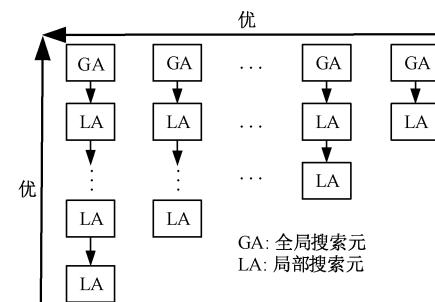


图 1 MOA 算法结构图

Fig. 1 MOA algorithm structure diagram

从图 1 中可知 MOA 算法多元化结构由全局搜索元( $G_a$ )与局部搜索元( $L_a$ )以多元结构链表组成,其中左侧  $G_a$  因评价指标较优而保留较多的  $L_a$ ,右侧  $G_a$  因评价指标较差而保留较少  $L_a$ ,使得更多评价指标较优全局及局部搜索个体参与记忆寻优过程,基本过程如下:

步骤 1) 设置局部半径、聚类个数、搜索元个数、最大迭代次数算法参数;

步骤 2) 在全局解空间进行全局搜索元  $G_a$  随机构建:

$$G_a = [unifrnd(l_1, u_1), \dots, unifrnd(l_d, u_d)] \quad (1)$$

其中,  $l_d$  与  $u_d$  分别为数据集中的每一维度中的最大与最小值;

步骤 3) 确定全局搜索元适应度值( $fitness$ ):

$$fitness = W_1 \times S_1 + W_2 \times S_2 \quad (2)$$

其中,  $S_1$ 、 $S_2$  分别为搜索元的类内距离值(式(3))与类间距离值(式(4)):

$$S_1 = \sum_{j=1}^K \sum_{\forall X_i \in Z_j} \|X_i - Z_j\|^2 \quad (3)$$

$$S_2 = \sum_{i=1}^K \sum_{j=i+1}^K \|Z_i - Z_j\|^2 \quad (4)$$

其中,式(1)中权值系数  $W_1 = 0.2$ 、 $W_2 = 0.8$ ,使得类内距离最小化、类间距离最大化,以保证聚类效果;

步骤 4)在全局搜索元局部半径下寻找更具潜力的局部搜索元  $L_a$ :

$$L_a = G_a + r \times [l_1, \dots, l_d] \quad (5)$$

其中,  $r$  为局部探索半径,  $l_d$  为  $-1 \sim 1$  的随机数;

步骤 5)将适应度值较优的搜索元作为高潜力搜索元存储于多元化结构进入下次迭代;

步骤 6)返回步骤 2)直至到达最大迭代次数。

## 1.2 基于网格筛选的密度峰值聚类算法

基于网格密度峰值聚类算法(grid density peaks clustering algorithm, GDPC)根据数据点的不均匀分布,采用网格化方法滤除部分稀疏网格数据点,有效增强了算法对高密度网格的关注度,并利用决策图策略快速预估聚类中心的位置,以确保聚类的准确性与高效性,基本流程如下:

步骤 1)设置截断距离、网格比例算法参数;

步骤 2)确定数据集网格划分长度  $\xi$ ,假设数据集的维度为  $k$ ,第  $\omega$  维的数值在区间  $[h_\omega, l_\omega]$  内,其中  $\omega = 1, 2, 3, \dots, k$ ,则:  $S = [h_1, l_1] \times \dots \times [h_k, l_k]$  代表  $k$  维空间,通过几何平均求解确定  $\xi$ :

$$\xi = a \times \left( \prod_{\omega=1}^k \frac{h_\omega - l_\omega}{m} \right)^{\frac{1}{k}} \quad (6)$$

其中,  $a \in [0.5, 1.5]$ <sup>[22]</sup> 为动态调节比例参数,  $m$  表示数据集样本总个数;

步骤 3)将数据集映射到根据式(6)划分的网格单元中,并计算每个网格密度  $\varphi_c$  为:

$$\varphi_c = N_c \quad (7)$$

其中,  $N_c$  表示第  $c$  个网格中数据点个数;

步骤 4)剔除  $\varphi_c$  较小网格单元内数据点,获得高密度数据集  $A = \{\vartheta_1, \vartheta_2, \dots, \vartheta_n\}$ ; 并计算  $A$  中数据点的局部密度  $\rho_i$ <sup>[23]</sup>:

$$\rho_i = \sum_j \chi(d_{ij} - d_c) \quad (8)$$

$$\chi(\ell) = \begin{cases} 1, & d_{ij} - d_c < 0 \\ 0, & \text{其他} \end{cases} \quad (9)$$

其中,  $d_c$  为截断半径,  $\rho_i$  为截断圆内与数据点  $i$  相邻的数据点个数;若  $d_c$  过大将导致不同簇的合并,其值过小将导致同一簇的分裂,故  $d_c$  应该使截断距离内的邻域样本数目为样本总数的 1%~2%;同时为降低主观选取  $d_c$  参数对聚类效果的影响,故采用高斯核函数改进  $\rho_i$  为:

$$\rho_i = \sum_{j=1}^n \exp\left(-\frac{d_{ij}^2}{d_c}\right) \quad (10)$$

步骤 5)确定各样本点  $x_i$  相对距离  $\delta_i$ :

$$\delta_i = \min_{\substack{j: \rho_j > \rho_i}} (d_{ij}) \quad (11)$$

表示样本点  $x_i$  与更高密度点的最小距离值;若  $x_i$  为密度最高样本,则相对距离  $\delta_i$  为:

$$\delta_i = \max_{i \neq j} (d_{ij}) \quad (12)$$

步骤 6)据  $\rho_i$  与  $\delta_i$  建决策图,将  $\rho_i$  和  $\delta_i$  都较大的点作为簇中心;

步骤 7)将数据集剩余数据点按照“最近邻”原则归于密度等于或高于“当前点”的最近点一类。

## 1.3 自适应多元优化局部放电识别算法

如前所述,MOA 算法搜索元构建具有随机性及相关参数的设定对实际环境下复杂 PD 故障识别具有较高针对性,不利于算法收敛和实际应用;而 GDPC 算法具有快速自发发现任意形状簇的高密度区域与自发优化参数特性;因此为进一步提高具有高聚集性、难分性、数据集各簇呈现状且细长以及密度不平衡性等复杂特征 PD 识别准确率,本文提出的 AMOA 算法通过 GDPC 算法的数据网格筛选过程有效提高了 MOA 算法对高密度数据区域的注意力与参数优化泛化能力,使得 MOA 可自适应调整复杂多变 PD 样本的识别参数,具体过程如图 2 所示。

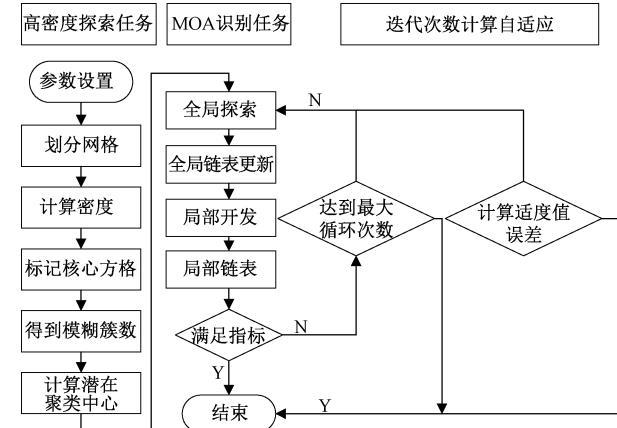


图 2 AMOA 算法结构图

Fig. 2 AMOA algorithm structure diagram

从图 2 可知,AMOA 算法首先通过 GDPC 确定 PD 故障数据集高密度区域后获得潜在聚类中心,然后通过潜在簇中心个数与簇内范围区间参数优化 MOA 聚类个数与搜索范围,避免式(1)与(2)搜索元的随机构建过程,最后充分发挥 MOA 动态搜索寻优能力对 PD 进行有效识别,其算法的具体过程详述如下:

步骤 1)设置参数局部半径、网格比例参数、搜索元个数、最大迭代次数算法参数;

步骤 2)采用 GDPC 算法网格化过程对数据样本  $X = \{x_1, x_2, \dots, x_m\}$  进行网格映射划分;

步骤 3)利用划分网格单元密度差异性,剔除单元格密度较小的网格数据点得到高密度数据集  $B = \{o_1, o_2, \dots,$

$o_u$ }, 并计算  $B$  的  $\rho_i$  与  $\delta_i$ ;

步骤 4)据  $\rho_i$  与  $\delta_i$  构建决策图, 将局部密度  $\rho_i$  与相对距离  $\delta_i$  较大的密度峰值点作为潜在簇中心;

步骤 5)以潜在簇中心个数与簇内范围区间参数分别优化多元优化 MOA 识别任务的聚类个数参数与搜索元寻优区间参数;

步骤 6)通过参数优化后的 MOA 识别任务进行高潜力全局局部交替搜索, 同时利用储存的过程信息  $fitness$  的一阶差分误差绝对值的变化进行自适应迭代过程, 即:

$$\Delta fitness_i = | fitness_i - fitness_{i-1} | \quad (13)$$

步骤 7)以适度值平均变化误差作为算法结束指标, 即:

$$\overline{\Delta fitness} = \frac{\sum \Delta fitness_i}{i} \quad (14)$$

其中,  $i$  代表迭代次数, 若  $\Delta fitness_i < \overline{\Delta fitness}$  代表适度值趋于稳定, 证明算法已经寻找最优聚类结果算法结束。

## 2 AMOA 算法 PD 识别实验

为说明 AMOA 算法的有效性, 将同时将其与 RDB、KPP、SVM-KNN、DPC-DLP、GWOKM、PSO、MOA 算法应用于电晕放电、悬浮放电、气隙放电、沿面放电四类典型 PD 故障相位分布图谱(phase resolved partial discharge, PRPD)数据集以及在实际工况下的 GIS 绝缘表面 PD 故障数据集的 PRPD 图谱特征, 并比较它们的识别准确性。相关实验在 Windows10 64 位操作系统, Intel(R) Core(TM) i7-10500@3.10 GHz CPU, 16 GB 内存设备上, 使用 MATLAB

R2020b 软件完成。

### 2.1 数据集介绍

为了验证算法对 PD 数据集识别的有效性, 采用高压设备电晕放电、悬浮放电、气隙放电、沿面放电四类典型 PD 数据集以及在实际工况施加 385 kV 与 375 kV 的电压下 GIS 绝缘表面 PD 故障数据集的 PRPD 图谱特征<sup>[24-25]</sup> 进行识别实验, 数据集的详细信息如表 1 所示。为保证实验的有效开展, 将删除数据集中具有缺失值的数据行。

表 1 局部放电数据集

Table 1 Partial discharge data set

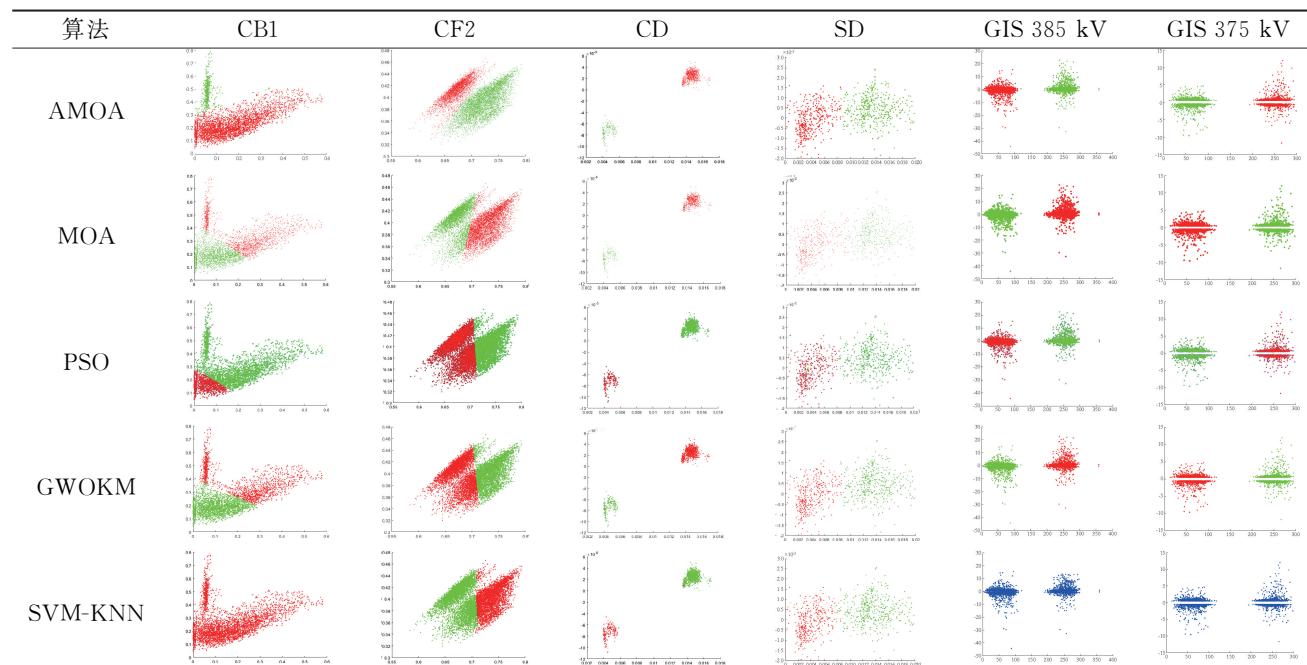
数据集	样本总数	簇数	维度
Corona_bobina_1(CB1)	3 788	2	2
Corona_floating_2(CF2)	9 056	2	2
Corona Discharge(CD)	864	2	2
Surface Discharge(SD)	795	2	2
GIS Surface Discharge(GIS 385 kV)	2 225	2	2
GIS Surface Discharge(GIS 375 kV)	1 900	2	2

### 2.2 实验结果

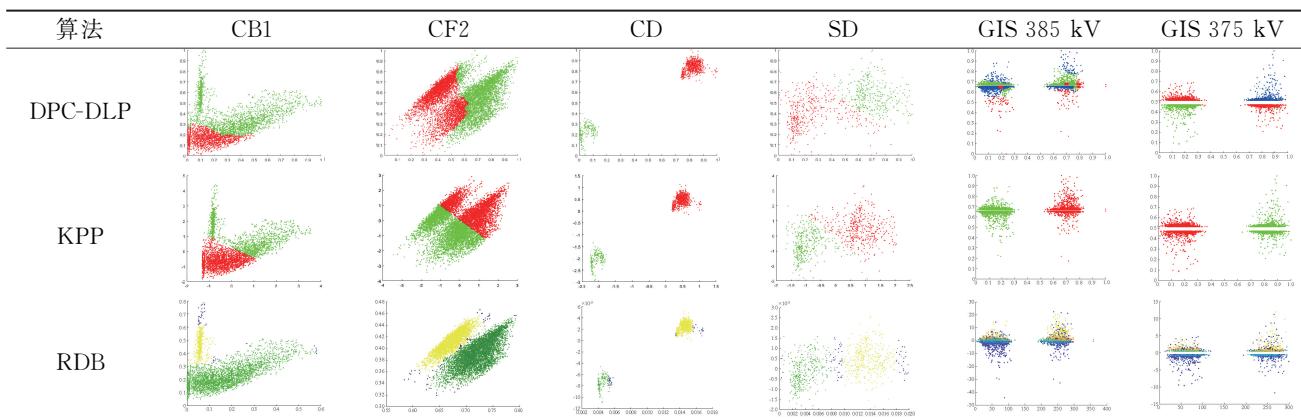
在对比实验中, 因 CB1、CF2、GIS 385 kV 与 GIS 375 kV 样本数目较多和分布较密集, 故 AMOA 算法  $a$  设为 1.2, 而 CD 与 SD 数据样本较少,  $a$  设为 0.7,  $r$  设置为 0.2, 搜索元个数为 10, 最大迭代次数均为 150 次进行聚类实验, 聚类效果图如表 2 所示。

表 2 算法聚类结果

Table 2 Algorithm clustering result



续表 2  
Continuation table 2



可见,在高密集 PD 故障数据集 CB1 与 CF2 上,AMOA 算法与 RDB 算法整体识别效果较好,但 RDB 算法对离散点的处理欠佳导致类别数多于真实数据集类别数。因 CD 数据集较为简单且满足高斯分布特性使得各类算法都能够较好地捕捉其内在结构。而对于难分性 SD 数据集而言,AMOA、GWOKM、SVM-KNN、MOA 和 PSO 算法聚类效果均表现较为出色;而在实际施加 385 kV 与 375 kV 的电压下 GIS 的真实缺陷 PD 故障数据集故障识别中,AMOA、MOA、GWO-KM、PSO、KPP 算法识别较好,但 SVM-KNN、DPC-DLP、RDB 算法识别效果欠佳。

总之,AMOA 算法对各类 PD 故障数据集均有较好的识别能力,可实现准确和稳定的故障识别。为进一步量化说明,列出了不同算法 10 次 PD 故障识别平均准确率如

表 3 所示。从中可知,GWOKM、SVM-KNN、DPC-DLP、MOA、PSO 算法对 CB1 与 CF2 非平衡性数据集识别平均准确率低于 89%,而 AMOA 与 RDB 算法识别平均准确率在 97% 以上;而 RDB 算法在 CD 与 SD 数据集上的 PD 识别平均准确率均低于 95%。AMOA 算法对 CD 与 SD 数据集的识别平均准确率均达到 99.8% 以上,同时 AMOA 算法对实际工况下的 GIS 绝缘表面 PD 故障识别率均达到 100%,而以 PD 故障数据集总体识别率为指标,AMOA 算法相较于 RDB、KPP、SVM-KNN、DPC-DLP、GWOKM、PSO 与 MOA 实验算法分别提高了 19.53%、13.04%、19.46%、37.18%、7.79%、8.13%、4.19%,有效说明本文提出的 AMOA 算法对高压设备 PD 识别具有更好效果。

表 3 准确率指标  
Table 3 Accuracy index

数据集 \ 算法	RDB	KPP	SVM-KNN	DPC-DLP	GWOKM	PSO	MOA	AMOA
CB1	97.7	71.73	86.3	56.23	73.251	71.25	86.299	98.6
CF2	98.9	53.83	73.52	75.96	76.48	76.48	88.3	98.02
CD	94.56	100	99.31	100	100	100	100	100
SD	91.19	92.7	98.365	90.94	100	100	96.73	99.87
GIS 385 kV	44.94	100	57.21	23.1	100	100	100	100
GIS 375 kV	52	100	65.053	27.2	100	100	100	100
总体识别率	79.88	86.38	79.96	62.24	91.62	91.29	95.22	99.42

为进一步评价 AMOA 算法对于具有较为复杂多变的特性 PD 识别的有效性,进一步计算了外部指标纯度(Purity)、调整兰德系数(adjusted rand index, ARI)、归一化互信息(normalized mutual information, NMI)参数如表 4~6 所示,可知 AMOA 算法对 PD 识别的平均 Purity、平均 ARI、平均 NMI 分别为 99.42%、99.39%、99.41%,均接近于 1,具有较优的识别效果,有效说明了 AMOA 算法的 PD 故障识别能力优于 RDB、KPP、SVM-KNN、DPC-

DLP、GWOKM、PSO、MOA 算法。

### 2.3 各方法运行时间

为进一步分析本文提出算法的实际可用性,列出了各算法对 4 种 PD 故障数据集的识别时间对比柱状图如图 3 所示;可知本文提出的 AMOA 算法对不同类型 PD 故障总体识别时间较少,说明 AMOA 算法通过自适应迭代过程可有效减少故障的识别时间,进一步说明了本文提出 AMOA 算法可对 PD 实现高效识别。

表 4 纯度指标  
Table 4 Purity index

数据集 \ 算法	%							
	RDB	KPP	SVM-KNN	DPC-DLP	GWOKM	PSO	MOA	AMOA
CB1	97.7	86.3	86.3	86.3	86.29	86.3	86.29	98.6
CF2	98.9	63.86	77.308	75.96	76.48	76.48	88.3	98.02
CD	94.56	100	99.306	100	100	100	100	100
SD	91.19	92.7	98.365	90.94	100	100	96.73	99.87
GIS 385 kV	58.29	100	45.36	78.2	100	100	100	100
GIS 375 kV	65.05	100	57.3	68.73	100	100	100	100
平均 Purity	84.28	90.48	77.32	83.36	93.80	93.80	95.22	99.42

表 5 调整兰德系数指标  
Table 5 ARI index

数据集 \ 算法	%							
	RDB	KPP	SVM-KNN	DPC-DLP	GWOKM	PSO	MOA	AMOA
CB1	81.9	16.58	0	0.37	15.874	15.87	86.299	98.56
CF2	97	0.57	29.73	26.93	27.975	27.97	88.3	97.91
CD	88.15	100	96.75	100	100	100	100	100
SD	83.18	72.91	93.56	67.01	100	100	96.73	99.86
GIS 385 kV	4.65	100	-1.43	-5.28	99.9	99.4	100	100
GIS 375 kV	3.02	99.3	0	-0.076	97.4	100	100	100
平均 ARI	59.65	64.89	36.44	31.49	73.52	73.87	95.22	99.39

表 6 归一化互信息指标  
Table 6 NMI index

数据集 \ 算法	%							
	RDB	KPP	SVM-KNN	DPC-DLP	GWOKM	PSO	MOA	AMOA
CB1	92.88	16.04	0	16.07	15.399	15.40	86.299	98.59
CF2	92.68	0.58	33.878	25.75	29.724	27.97	88.3	97.99
CD	79.91	100	92.79	100	100	100	100	100
SD	79.33	62.92	89.551	62.23	100	100	96.73	99.87
GIS 385 kV	31.28	98.8	-1.94	7.37	99.2	100	100	100
GIS 375 kV	23.54	100	0	1.97	100	98.9	100	100
平均 NMI	66.60	63.06	35.71	35.57	74.05	73.71	95.22	99.41

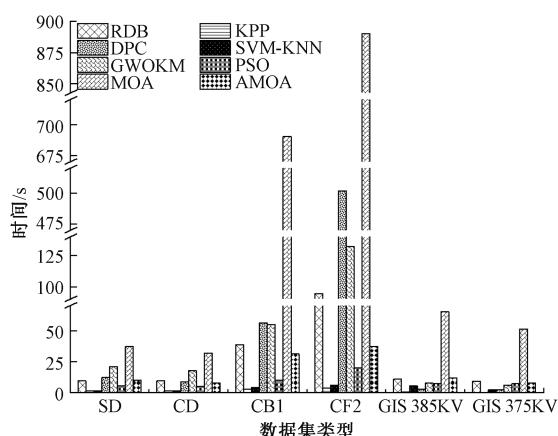


图 3 算法时间图  
Fig. 3 Algorithmic time graph

### 3 AMOA 算法非 PD 识别泛化实验

#### 3.1 数据集介绍

为进一步说明 AMOA 算法的泛化性, 实验将其应用具有不同维度的 UCI 数据集如表 7 所示。

表 7 UCI 数据集  
Table 7 UCI data set

数据集	样本总数	簇数	维度
Iris	150	3	4
Haberman	150	2	3
Wine	178	3	13
Cancer	685	2	9

### 3.2 非 PD 泛化识别结果

实验中 AMOA 算法的  $a$  设为 0.8,  $r$  为 0.2, 搜索元个数为 10, 迭代最大次数均为 150 次, 采用欧式距离作为评价函数进行聚类实验, 10 次实验结果平均识别准确率如表 8 所示, 可知本文提出的 AMOA 算法对以上常用数据集的平均识别准确率分别高于 MOA 算法 5.34%、1.64%、11.3%、0.68%, 有效说明了 AMOA 算法对非 PD 数据具有较优的识别泛化性。

表 8 非 PD 实验识别结果

Table 8 Identification results of non-PD experiments

数据集	MOA 识别率	AMOA 识别率	%
Iris	89.99	95.33	
Wine	95.55	97.19	
Haberman	73.53	84.83	
Cancer	96.49	97.17	

## 4 结 论

为进一步提高 PD 故障识别准确率, 本文提出了自适应多元优化局部放电识别算法, 用于 PD 类型的故障识别, 并与 RDB、KPP、SVM-KNN、DPC-DLP、GWOKM、PSO、MOA 算法进行了对比, 得到结论如下:

本文结合了多模态 MOA 算法搜索框架与 GDPC 算法参数优化模式, 提出了 AMOA 改进算法对 PD 故障进行识别, 加强了对 MOA 任务的高密度区域注意力, 以高密度区域潜在簇进行优化 MOA 参数。

AMOA 算法对高压设备的 4 类 PD 故障和在实际工况施加下 385 kV 与 375 kV 的电压下 GIS 绝缘表面 PD 故障进行较好的识别, 总体平均识别准确率达到了 99.42%, 在同等计算资源下 AMOA 相较于 MOA 计算速度提升了近 10 倍, 对指导实际工况下的 PD 故障识别具有一定意义。

本文提出的 AMOA 算法的相较 MOA 算法而言, 其拥有更强的寻优能力, 对非 PD 数据 Iris、Haberman、Wine、Cancer 的总体平均识别准确率达到了 93.625%, 证明了 AMOA 算法对非 PD 数据集也具有较好的识别泛化性。

## 参考文献

- [1] 郑艳艳, 朱永利, 高佳程. 基于支持向量回归的 VPMCD 方法及其在局部放电模式识别中的应用[J]. 华北电力大学学报(自然科学版), 2019, 46(2): 19-24, 68.
- [2] 范路, 陆云才, 陶风波, 等. 人工智能在局部放电检测中的应用(二): 模式识别与状态评估[J]. 绝缘材料, 2021, 54(7): 10-24.
- [3] FAN L, LU Y C, TAO F B, et al. Application of artificial intelligence in partial discharge detection part II: Pattern recognition and condition assessment[J]. Insulating Materials, 2021, 54(7): 10-24.
- [4] 王利福, 刘屹江泽, 王懿增. 基于 EEMD 能量矩与 ISSA-SVM 算法的 GIS 局部放电类型识别方法[J]. 电子测量与仪器学报, 2022, 36(5): 204-212.
- [5] WANG L F, LIU Y J Z, WANG Y Z. Partial discharge identification method in GIS based on EEMD energy moment and ISSA-SVM algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(5): 204-212.
- [6] 倪鹤立, 傅晨钊, 胡海敏, 等. 电气设备局部放电脉冲电流法检测技术述评[J]. 高压电器, 2023, 59(11): 1-14.
- [7] NI H L, FU CH ZH, HU H M, et al. Review on detection technique of pulse current method for PD measurement of electrical equipment [J]. High Voltage Apparatus, 2023, 59(11): 1-14.
- [8] 李泽, 钱勇, 赵九一, 等. GIS 局部放电光学传感器仿真设计与试验研究[J]. 仪器仪表学报, 2023, 44(8): 249-257.
- [9] LI Z, QIAN Y, ZHAO J Y, et al. Simulation design and experimental study of GIS partial discharge optical sensors[J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 249-257.
- [10] 孙源, 宋颜峰, 王昊天, 等. 开关柜局部放电超声-TEV 融合检测技术[J]. 高电压技术, 2023, 49(12): 5052-5060.
- [11] SUN Y, SONG Y F, WANG H T, et al. Ultrasonic-TEV combined detection technology of partial discharge in switchgear [J]. High Voltage Engineering, 2023, 49(12): 5052-5060.
- [12] 唐志国, 唐铭泽, 李金忠, 等. 电气设备局部放电模式识别研究综述[J]. 高电压技术, 2017, 43(7): 2263-2277.
- [13] TANG ZH G, TANG M Z, LI J ZH, et al. Review on partial discharge pattern recognition of electrical equipment [J]. High Voltage Engineering, 2017, 43(7): 2263-2277.
- [14] 褚鑫, 张建文, 韩刚. 统计特征参数及多分类 SVM 的局部放电类型识别[J]. 电测与仪表, 2015, 52(7): 35-39, 96.
- [15] CHU X, ZHANG J W, HAN G. Partial discharge pattern recognition based on statistical parameters and multi-classifications SVM[J]. Electrical Measurement & Instrumentation, 2015, 52(7): 35-39, 96.
- [16] 宋人杰, 杨爽, 孟凡奇. 基于多核学习整合 GIS 局部放电多类特征的分类研究[J]. 北京交通大学学报, 2018, 42(5): 93-98, 140.
- [17] SONG R J, YANG SH, MENG F Q. Research on Classification of multi-class partial discharge features

- in GIS based on multiple Kernel learning[J]. Journal of Beijing Jiaotong University, 2018, 42 (5): 93-98,140.
- [10] DUDANI K, CHUDASAMA A R. Partial discharge detection in transformer using adaptive grey wolf optimizer based acoustic emission technique [J]. Cogent Engineering, 2016, 3(1): 1256083.
- [11] 陈健宁,周远翔,白正,等.基于多通道卷积神经网络的油纸绝缘局部放电模式识别方法[J].高电压技术,2022,48(5):1705-1715.
- CHEN J N, ZHOU Y X, BAI ZH, et al. Pattern recognition method of partial discharge in oil-paper insulation based on Multi-channel convolutional neural network[J]. High Voltage Engineering, 2022, 48(5): 1705-1715.
- [12] 汪志成,王泽旺,朱梦帆,等.基于卷积神经网络的局部放电声音识别研究[J].电子测量技术,2023,46(20):148-155.
- WANG ZH CH, WANG Z W, ZHU M F, et al. Study on sound recognition of partial discharge based on convolutional neural network [J]. Electronic Measurement Technology, 2023, 46(20): 148-155.
- [13] HEREDIA L C C, MOR A R. Density-based clustering methods for unsupervised separation of partial discharge sources[J]. International Journal of Electrical Power & Energy Systems, 2019, 107: 224-230.
- [14] 李宝磊,施心陵,苟常兴,等.多元优化算法及其收敛性分析[J].自动化学报,2015,41(5):949-959.
- LI B L, SHI X L, GOU CH X, et al. Multivariate optimization algorithm and its convergence analysis [J]. Acta Automatica Sinica, 2015, 41(5): 949-959.
- [15] BRYANT A, CIOS K. RNN-DBSCAN: A density-based clustering algorithm using reverse nearest neighbor density estimates[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30: 1109-1121.
- [16] 戴志辉,张艺宏,于礼瑞,等.适用于新型配电网的改进型电流保护[J].华北电力大学学报(自然科学版),2024,51(1):1-9,19,10.
- DAI ZH H, ZHANG Y H, YU L R, et al. Improved current protection suitable for new distribution network[J]. Journal of North China Electric Power University(Natural Science Edition), 2024, 51(1): 1-9,19,10.
- [17] MACHHALE K, NANDPURU H B, KAPUR V, et al. MRI brain cancer classification using hybrid classifier (SVM-KNN) [C]. 2015 International Conference on Industrial Instrumentation and Control(ICIC). IEEE, 2015: 60-65.
- [18] SEYEDI S A, LOTFI A, MORADI P, et al. Dynamic graph-based label propagation for density peaks clustering [J]. Expert Systems with Applications, 2019, 115: 314-328.
- [19] DAVIRAN M, GHEZELBASH R, MAGHSOUDI A. GWOKM: A novel hybrid optimization algorithm for geochemical anomaly detection based on Grey wolf optimizer and K-means clustering[J]. Geochemistry, 2024, 84(1):2-13.
- [20] ESMIN A A A, COELHO R A, MATWIN S. A review on particle swarm optimization algorithm and its variants to clustering high-dimensional data[J]. Artificial Intelligence Review, 2015, 44: 23-45.
- [21] 李孙寸,施心陵,张松海,等.基于多元优化算法的三维装箱问题的研究[J].自动化学报,2018,44 (1): 106-115.
- LI S C, SHI X L, ZHANG S H, et al. Multi-variant optimization algorithm for three dimensional container loading problem[J]. Acta Automatica Sinica, 2018, 44(1): 106-115.
- [22] 徐晓,丁世飞,孙统风,等.基于网格筛选的大规模密度峰值聚类算法[J].计算机研究与发展,2018,55(11):2419-2429.
- XU X, DING SH F, SUN T F, et al. Large-scale density peak clustering algorithm based on grid screening [J]. Journal of Computer Research and Development, 2018, 55(11): 2419-2429.
- [23] 李启文,王治和,杜辉,等.基于高斯分布的自适应密度峰值聚类算法[J/OL].计算机工程:1-12[2024-07-09].  
<https://doi.org/10.19678/j.issn.1000-3428.0068956>. LI Q W, WANG ZH H, DU H, et al. Adaptive Density Peak Clustering Algorithm Based on Gaussian Distribution [J/OL]. Computer Engineering: 1-12 [ 2024-07-09 ]. <https://doi.org/10.19678/j.issn.1000-3428.0068956>.
- [24] RAHMAN M A, ANG L M, SENG K P. An automated identification approach for partial discharge detection using density-based clustering without user inputs [ J ]. IEEE Transactions on Artificial Intelligence, 2023.
- [25] WU Z, LYU B, ZHANG Q, et al. Phase-space joint resolved PD characteristics of defects on insulator surface in GIS[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27(1): 156-163.

## 作者简介

夏金平,硕士研究生,主要研究方向为高压设备的局部放电故障检测技术。

E-mail:2664649807@qq.com

高莲(通信作者),博士,讲师,主要研究方向为电力数据挖掘、电力信息物理融合系统研究。

E-mail:962245641@qq.com

李鹏,博士,副教授,主要研究方向为智能电网运行和控制、电力信息物理融合系统。

E-mail:lipeng@ynu.edu.cn

陈昌川,博士,副教授,主要研究方向为图像处理与 AI、智能信息处理、特高频局放检测、红外成像与测温研究。

E-mail:creditdegree@gmail.com