

DOI: 10.13382/j.jemi.B2408062

基于 IOOA 优化 GRU-GASF-RP-ViT 的万能式 断路器故障诊断*

李 斌 王志鹏 王幸之

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要: 万能式断路器 (air circuit breaker, ACB) 作为配电系统中重要的保护设备, 其故障诊断对电力系统稳定运行至关重要。然而传统的单一模态模型在特征提取时, 不能全面地筛选数据特征, 导致故障诊断准确率下降。针对此问题提出了一种改进鱼鹰算法 (IOOA) 优化门控循环单元-格拉姆角和场-递归图-视觉转换器 (GRU-GASF-RP-ViT) 的万能式断路器故障诊断模型。该模型将一维信号和二维图像特征融合在一起, 从时序和空间的角度更全面地描述数据的特征, 提高故障分类和识别的准确性。首先通过 GASF 和 RP 分别将一维振动信号转换为两组二维图像。然后利用双支路 ViT 有效地学习两组二维图像的空间特征和局部特征。另一支路通过 GRU 来捕获一维时序信号中的动态变化和趋势, 实现 GRU 与全新的双支路 ViT 并行结合。针对模型中难以确定的超参数, 引入 IOOA 对参数进行寻优改进, 使模型更加合理。最后搭建断路器故障模拟实验平台, 通过与其他 6 种模型的对比, 准确率提升 3.3%~13.3%, 验证了所提模型具有更高的诊断精度。

关键词: 万能式断路器; 改进鱼鹰算法; 多模态融合; Vision Transformer; 故障诊断

中图分类号: TM561.1; TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault diagnosis of air circuit breaker based on IOOA optimized GRU-GASF-RP-ViT

Li Bin Wang Zhipeng Wang Xingzhi

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

Abstract: As an important protection equipment in distribution system, the fault diagnosis of universal circuit breaker (ACB) is very important for the stable operation of power system. However, the traditional single-modal model cannot fully describe the characteristics of the data when extracting features, resulting in a decrease in the accuracy of fault diagnosis. To solve this problem, this paper proposes an improved osprey algorithm to optimize the gated recurrent unit-graham angle and field-recurrence plot-vision transformer (GRU-GASF-RP-ViT) universal circuit breaker fault diagnosis model. The model combines one-dimensional signal and two-dimensional image features to describe the characteristics of the data more comprehensively from the perspective of time series and space. The accuracy of fault classification and recognition is improved. Firstly, the one-dimensional vibration signal is converted into two sets of two-dimensional images by GASF and RP respectively. Then, the two-branch ViT is used to effectively learn the spatial and local features of the two sets of two-dimensional images. The other branch captures the dynamic changes and trends in the one-dimensional time series signal through the GRU, and realizes the parallel combination of GRU and the new two-branch ViT. For the hyperparameters that are difficult to determine in the model. The improved osprey algorithm is introduced to optimize the parameters to make the model more reasonable. Finally, a circuit breaker fault simulation experiment platform is built. By comparing with the other four models, the accuracy rate has increased by 3.3%~13.3%, it is verified that the proposed model has higher diagnostic accuracy.

Keywords: air circuit breaker; improve the fish-eagle algorithm; multimodal fusion; vision transformer; fault diagnosis

0 引言

万能式断路器 (air circuit breaker, ACB) 是低压配电系统中的重要保护装置,常安装在工业、商业及公共设施的配电网中,承担着保障电路安全、设备稳定运行的重要责任^[1]。当断路器出现故障问题时,可能会导致电力传输受阻,对工业生产、居民生活和公共服务造成严重影响,进而带来不可预估的安全隐患和财产损失^[2]。因此对于 ACB 的精准故障识别具有重要的意义。

ACB 在动作过程中,动静触头的碰撞会产生剧烈的振动信号,该信号不仅采集过程简单高效,而且还包含着丰富的机械信息^[3]。目前许多国内外学者都提出利用振动信号检测机械设备的故障。马莉等^[4]提出了一种均值聚类与支持向量机相结合的训练模型,利用变分模式分解 (variational mode decomposition, VMD) 将声振联合信号的各模态分量输入到该模型进行训练,实现了高压断路器机械故障的识别。范兴明等^[5]利用逐次变分模式分解对振动信号进行分解,通过改进蜚螂优化的深度混合核极限学习机模型进行训练,在高压断路器的诊断上取得了良好的效果。宋金波等^[6]将振动信号输入到一维卷积神经网络和门控循环单元 (gate recurrent unit, GRU) 的结合网络,该模型能够有效捕捉轴承振动信号的动态变化和趋势;实现了对于轴承的故障分类。从上述研究可以得出,一维时序信号中包含着丰富的时频信息,结合机器学习中的模型能够很好反映出断路器的故障状态,但时序振动信号自身受噪声影响较大,而且在面对复杂信号时无法完全将内部包含的瞬态特征信息体现出来,从而直接影响故障诊断的准确率。

近些年,一维时序信号转换为二维图片的方法得到快速应用,图片信号的特征提取在深度学习中也取得了一定效果。鄢仁武等^[7]提出利用连续小波变换进行时频特征图的转换,通过卷积神经网络识别高压断路器的故障。孙曙光等^[8]将时频图引入到一种单信号输入和多任务输出的残差网络中,并通过模拟的触头系统的故障实验,证明了对于 ACB 故障诊断和程度评估的有效性。司江宽等^[9]将处理后的振动信号通过格拉姆角场转换为二维图像,筛选后的重要特征输入到集成学习模型 (adaptive boosting, AdaBoost) 进行断路器故障识别。樊红卫等^[10]将视觉转换器 (vision transformer, ViT) 替换传统卷积神经网络,对轴承振动信号转换的时频图像进行特征提取,最后通过实验验证,成功实现了滚动轴承的故障识别。由此可见,二维图像作为特征分量能够很好的反映出非周期信号的全局信息,大幅度提高了模型的训练效率,但在图像转换上,需要复杂的预处理,这样会导致丢失部分原始信号本身的特征信息,从而影响诊断

性能。

针对上述方法上的不足,本文提出了一种改进鱼鹰算法 (improved osprey optimization algorithm, IOOA) 优化 GRU-格拉姆角场 (GASF)-递归图 (RP)-ViT 的万能式断路器故障诊断模型。该模型将一维时序信号和二维图像两种不同模式进行特征融合,一维时序信号采用 GRU 进行特征提取。但是 GRU 结构简单,在面对复杂时间序列时提取特征较为困难,针对 GRU 的不足,另外设计两条支路进行特征融合,通过 GASF 和 RP 分别将一维振动信号转换为两组二维图像;其中 GASF 图像捕捉全局趋势,RP 图像突出局部非线性特征,两者结合丰富了特征空间,通过双支路视觉 Transformer 分别提取图像的空间特征和局部特征。利用 ViT 识别图像复杂特征能力强的优点,弥补门控循环单元的不足。最后针对模型中难以确定的超参数加入改进鱼鹰算法进行参数寻优,提高模型的稳定性。

1 基于 GASF-RP-ViT 的图像特征提取

1.1 GASF

GASF^[11]是一种将时序数据转换为二维图像的数据处理方法,它通过 Gramian 角域特殊的内积方式,将时序序列中两点之间角度和的信息,从左下到右上呈现在二维图像上,最大程度的保留时序信号的全局趋势特征。

首先将一维时序序列中的数值 $X = \{x_1, x_2, \dots, x_n\}$ 缩放至 $[-1, 1]$ 之间,如式(1)所示。

$$\vec{x}_1 = \frac{x_i - \max(X) + x_i - \min(X)}{\max(X) - \min(X)} \quad (1)$$

式中: i 为时间点, $i \in [1, n]$ 。将式(1)处理后的时序序列变换为极坐标向量,其变换公式如下:

$$\begin{cases} \phi = \arccos(\vec{x}_1), & -1 \leq \vec{x}_1 \leq 1, \vec{x}_1 \in \vec{X} \\ r = \frac{t_1}{N}, & t_1 = 1, 2, \dots, N \end{cases} \quad (2)$$

式中: t_i 为时间戳; N 为正则化极坐标生成空间的常数因子; r 为极坐标半径; ϕ 表示相角; \vec{X} 为标准化缩放后的 X 。

利用余弦函数计算不同时间点的内积,有效地保留了时间序列的趋势信息和相对位置关系,最终得到 GASF 矩阵如式(3),GASF 编码过程如图 1 所示。

$$C_{GASF} = \begin{bmatrix} \cos(\phi_1 + \phi_1) \cdots \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) \cdots \cos(\phi_2 + \phi_n) \\ \vdots \\ \cos(\phi_n + \phi_1) \cdots \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

1.2 RP

RP^[12]是一种通过相位空间将一维时间序列数据转




图 1 GASF 二维图像编码过程

Fig. 1 GASF 2D image coding process

换为二维图像的可视化工具,基本原理是利用相空间重构将时序信号映射到高维空间,在高维空间中计算时间序列在不同时刻之间的相似性结构和规律,并表现在二维图像上。主要用于分析非线性时间序列中的动态模式和递归行为。

根据选择的嵌入维度 m 和延迟时间 τ ,将采集的一维时间序列 (I_1, I_2, \dots, I_n) 利用延迟坐标嵌入法构建相位空间 \vec{s}_i ,重建后如下:

$$\vec{s}_i = (I_i, I_{i+\tau}, \dots, I_{i+(m-1)\tau}) \quad (4)$$

在相空间中计算不同时间点对应状态向量之间的欧

氏距离。如式(5)所示:

$$d_{i,j} = \|\vec{s}_i - \vec{s}_j\| \quad (5)$$

则递归图递归过程如下:

$$\mathbf{R}_{i,j}(\varepsilon) = \delta(\varepsilon - d_{i,j}), \forall i, j \in \{1, \dots, n - (m-1)\tau\} \quad (6)$$

$$\delta(t) = \begin{cases} 0, & t < 1 \\ 1, & \text{其他} \end{cases} \quad (7)$$

式中: $\mathbf{R}_{i,j}(\varepsilon)$ 是一个 $N \times N$ 的方阵,其中 ε 为最小距离的阈值使得 $\mathbf{R}_{i,j} \in \{0, 1\}$; δ 为 Heaviside 函数。RP 生成二维图像过程如图 2 所示。




图 2 RP 二维图像编码过程

Fig. 2 RP 2D image coding process

1.3 ViT

为尽可能减少 RP 和 GASF 二维图像特征的损失,本文采用了基于注意力机制的 ViT^[13-14] 模型对图像特征提取。ViT 通过内部的多头自注意力机制能够有效捕捉图像的全局特征,这种全局感知能力使其在处理二维图像数据时尤为适用。但本文仅将 ViT 用于图像特征提取,舍弃了其自带的多层感知机 (MLP head) 分类模块,直接输出特征序列以供后续处理。其内部集合了图像块嵌入、位置编码和 Transformer 编码器。

1) 图像划分及位置编码

首先将二维图像(以 GASF 图为例)划分为固定大小像素的二维图像块(patch),然后进入 Embedding 层,通过可学习的线性变换将这些图像块展平为一维 Transformer 向量(token)。在这个过程中,原始二维图像的位置信息被破坏,因此,在线性投影的过程中,引入了带有空间信息的一维位置编码(positional encoding),附加在 Token 上,最后将形成序列和它们对应的位置编码通过线性投影编码送入编码器进行训练^[15]。数学模型如下:

$$\mathbf{z}_0 = [\mathbf{x}_{class}; \mathbf{x}_p^1 E; \mathbf{x}_p^2 E; \dots; \mathbf{x}_p^N E] + E_{pos}$$

$$E \in R^{(P^2 \cdot C) \times D}, E_{pos} \in R^{(N+1) \times D} \quad (8)$$

式中: $\mathbf{x}_p^i E$ 表示嵌入的图像块 $i \in 1, 2, \dots, N$; \mathbf{x}_{class} 为类别向量; E_{pos} 为位置编码; \mathbf{z}_0 表示输入向量。

2) Transformer 编码器

ViT 网络主要利用 Transformer 编码器进行特征提取,内部主要含有多头自注意力机制层^[16] (multi-head attention block, MSA)、前馈神经网络^[17] (feedforward neural network, FNN)、层归一化及残差连接如图 3 所示。其中 MSA 作为编码器结构的核心单元,主要采用了高效的全局注意机制来捕捉 Token 之间的关系。允许每个 Token 与其他 Token 交换信息,加强捕捉输入图像丰富特征信息的能力,从而建立原始图像特征的长距离依赖关系。MSA 数学模型如下:

$$\mathbf{z}'_l = \text{MSA}(\text{LN}(\mathbf{z}_{l-1})) + \mathbf{z}_{l-1}, l = 1, \dots, L \quad (9)$$

式中: LN 表示为层归一化处理函数; \mathbf{z}_{l-1} 表示上一层的残差连接; L 表示重复次数。

在 MSA 机制中,输入的每个 Token 会经过线性变换生成 3 个重要的向量,查询(Q)、键(K)和值(V)。通过计算查询和键的点积相似度获得权重,利用这些权重对值向量进行加权处理,最终生成注意力的输出。表达式

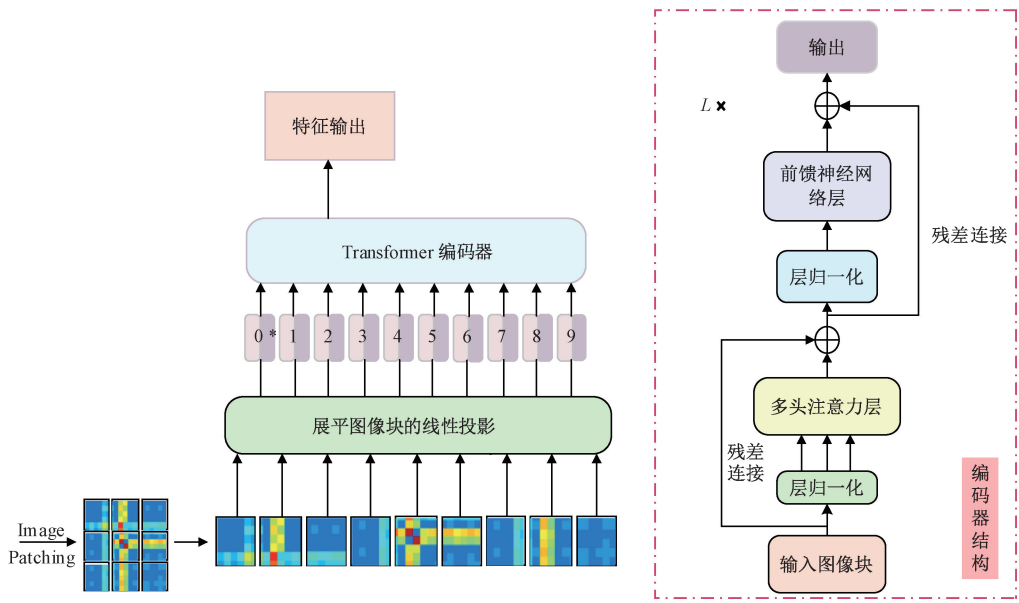


图 3 Vision Transformer 模型结构
Fig. 3 Vision Transformer model structure

如下:

$$Q = XW_Q, K = XW_K, V = XW_V \quad (10)$$

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (11)$$

式中: X 为输入矩阵; W_Q, W_K, W_V 是可学习的权重矩阵; QK^T 是计算查询与键的点积; d_k 为向量的维度; $\sqrt{d_k}$ 是缩放因子; $softmax$ 用于分配合适权重。

最后将输入向量转换的的注意力头进行输出拼接, 通过一个线性变换获得最终输出, 表达式如下:

$$head_h = Attention(Q_h, K_h, V_h) \quad (12)$$

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_H)W_o \quad (13)$$

式中: W_o 为 MSA 的权值矩阵; H 为头数。除了 MSA 外, 编码器中还包含了全连接的前馈神经网络。用于对每个位置的特征进行非线性变换和映射, 帮助捕捉更复杂的特征关系。表达式如下:

$$FFN(x) = ReLU(xW_1 + b_1)W_2 + b_2 \quad (14)$$

$$z_l = FFN(LN(z'_l)) + z'_l \quad l = 1, \dots, L \quad (15)$$

式中: W_1, W_2 和 b_1, b_2 分别为第 1 个和第 2 个线性变换的权重和偏置; z'_l 为 MSA 输出。

为了增强模型的扩展性, 避免信息在深层处理过程中出现退化现象, ViT 中的每个子层引入了残差连接, 确保梯度能够高效传播。每个子层在输入计算之前使用层归一化, 调整输入分布并稳定训练过程。这种“Pre-Norm”设计进一步提升了深层模型的训练稳定性和表达能力^[18], 使其能够更高效地捕获图像的复杂特征。

2 GRU 时序信号特征提取

GRU 是一种时间序列数据的信息提取技术, 结构和功能与长短期记忆网络 (long short term memory, LSTM) 相似, 都通过门控机制控制输入、记忆等信息。既可以处理由于反向传播存在的梯度消失或爆炸问题, 又能够建立输入序列中的长短期依赖关系, 发挥类似记忆单元的作用。GRU 结构如图 4 所示。




图 4 门控循环单元结构
Fig. 4 Gated cycle unit structure

重置门 r_t 通过权值系数 W_r 和 b_r 决定上一时刻的状态信息能够被保留到当前时刻 x_t 记忆中的程度。重置门公式如下:

$$R_t = \sigma(W_R [h_{t-1}, x_t] + b_R) \quad (16)$$

GRU 的更新门 Z_t 通过权值系数 W_z 和 b_z 决定上一时刻的状态信息能够被保留到当前时刻 x_t 记忆中的程度:

$$Z_i = \sigma(W_Z[h_{i-1}, x_i] + b_Z) \quad (17)$$

最后,中间隐藏输出状态 h_i' 综合了当前时刻输入序列 x_i ,上一位输出 h_{i-1} 和重置门 r_i 的共同作用,公式如下:

$$h_i' = \tanh(W[h_i \cdot h_{i-1}, x_i] + b) \quad (18)$$

隐藏输出状态 h_i 由上一时刻的状态和当前时刻的初步输出状态共同决定,如式(19)所示。

$$h_i = (1 - Z_i)h_{i-1} + Z_i h_i' \quad (19)$$

3 超参数优化

3.1 鱼鹰优化算法(OOA)

由于 ACB 故障诊断模型中有难以确定的 GRU 单元数、学习率、MSA 和 ViT 层数等超参数,所以引入 IOOA 对超参数进行优化,提高模型的构建效率。鱼鹰优化算法是 Dehghani 等^[19]于 2023 年提出的一种受鱼鹰捕食行为启发的优化算法,其主要包括了定位捕鱼,安全进食两个阶段。

与大多数的优化算法类似,首先在寻优空间里随机设置种群初始化:

$$x_{i,j} = lb_j + rand(ub_j - lb_j) \quad (20)$$

式中: lb_j, ub_j 分别为鱼鹰寻优范围的上下边界; $x_{i,j}$ 为第 i 个第 j 维的鱼鹰; $rand$ 为 $[0, 1]$ 的随机数。

定位捕鱼阶段数学模型如下:

$$FP_i = \{X_k \mid k \in \{1, 2, \dots, N\} \wedge F_k < F_i\} \cup \{X_{best}\} \quad (21)$$

$$x_{i,j}^{p_1} = x_{i,j} + r_{i,j} \cdot (SF_{i,j} - I_{i,j} \cdot x_{i,j}) \quad (22)$$

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j}^{p_1}, lb_j \leq x_{i,j}^{p_1} \leq ub_j \\ lb_j, x_{i,j}^{p_1} < lb_j \\ ub_j, x_{i,j}^{p_1} > ub_j \end{cases} \quad (23)$$

$$X_i = \begin{cases} X_i^{p_1}, F_i^{p_1} < F_i \\ X_i, \text{其他} \end{cases} \quad (24)$$

式中: FP_i 是鱼鹰目标鱼群的集合; X_{best} 是所处的最佳位置; $SF_{i,j}$ 是在鱼群中随机选中的鱼个体; $x_{i,j}^{p_1}$ 为第 i 只鱼鹰在捕鱼阶段时所处在第 j 维的新位置; $F_i^{p_1}$ 是其对应的适应度值; r 为 $[0, 1]$ 之间的随机数; $I_{i,j}$ 为集合 $[1, 2]$ 的任意数。

进食阶段利用鱼鹰捕鱼后,将鱼带到安全位置的微小变化再次进行位置更新,数学模型如下:

$$x_{i,j}^{p_2} = x_{i,j} + \frac{lb_j + r \cdot (ub_j - lb_j)}{t} \quad (25)$$

$i = 1, 2, \dots, N; j = 1, 2, \dots, m; t = 1, 2, \dots, T$

$$x_{i,j}^{p_2} = \begin{cases} x_{i,j}^{p_2}, lb_j \leq x_{i,j}^{p_2} \leq ub_j \\ lb_j, x_{i,j}^{p_2} < lb_j \\ ub_j, x_{i,j}^{p_2} > ub_j \end{cases} \quad (26)$$

$$X_i = \begin{cases} X_i^{p_2}, F_i^{p_2} < F_i \\ X_i, \text{其他} \end{cases} \quad (27)$$

式中: $x_{i,j}^{p_2}$ 为第 i 只鱼鹰进食阶段时所处在第 j 维的新位置; $F_i^{p_2}$ 是其对应的适应度值; t 为迭代次数; T 为最大迭代次数。

3.2 改进鱼鹰优化算法

1) Circle 混沌映射初始化种群

本文采用 Circle 混沌映射^[20]改进鱼鹰算法的种群初始化阶段, Circle 种群初始化分布如图 5 所示,公式如下:

$$x_{k+1} = \text{mod}(x_k + 0.2 - \left(\frac{0.5}{2\pi}\right)\sin(2\pi x_k), 1) \quad (28)$$

式中: mod 为取余函数; k 取值 3 000。




图 5 Circle 混沌映射初始化种群的分布

Fig. 5 Distribution of initial population of circle chaotic map

2) 引入记忆功能

引入记忆功能来加强鱼鹰算法的探索阶段,将全局最优位置引入传统公式中,根据最优位置和当前位置控制鱼鹰的移动,该方法有效避免了 OOA 搜索后期易陷入局部极值的问题^[21],提高了算法的搜索精度。更新后数学模型如下:

$$x_{i,j}^{p_1} = x_{i,j} + r_1 \cdot (SF_{i,j} - I_{i,j} \cdot x_{i,j}) + r_2 \cdot (SF_{i,j} - I_{i,j} \cdot x_{best}) \quad (29)$$

式中: r_1, r_2 为 $[0, 1]$ 之间的随机数; x_{best} 为全局最优位置。

3) 莱维(Levy)飞行策略

Levy 飞行策略产生随机步长的局部搜索能够相对扩大 OOA 的局部开发能力,使得鱼鹰在进行局部寻优时提升收敛精度;提高了算法跳出局部最优的能力。

Levy 随机步长公式如下:

$$Levy(\beta) = \frac{\mu}{|\nu|^{\frac{1}{\beta}}} \quad (30)$$

式中： ν 为标准正态分布随机变量； μ 为拓展参数； β 为决定步长特性的参数。为了更好地控制莱维飞行的收敛速度及精度引入了非线性动态因子 λ 对其进行改进。 λ 取值及调整后的莱维飞行公式如下：

$$\begin{cases} Levy(\lambda) = \lambda \cdot Levy(\beta) \\ \lambda = 0.5(1 - t/T)^2 \end{cases} \quad (31)$$

调整后莱维飞行其位置更新公式如式 (32) 所示。IOOA 流程如图 6 所示。

$$x_{i,j}^{t+1} = x_{i,j}^t + Levy(\lambda) \oplus \frac{lb_j + r \cdot (ub_j - lb_j)}{t} \quad (32)$$

$i = 1, 2, \dots, N; j = 1, 2, \dots, m; t = 1, 2, \dots, T$

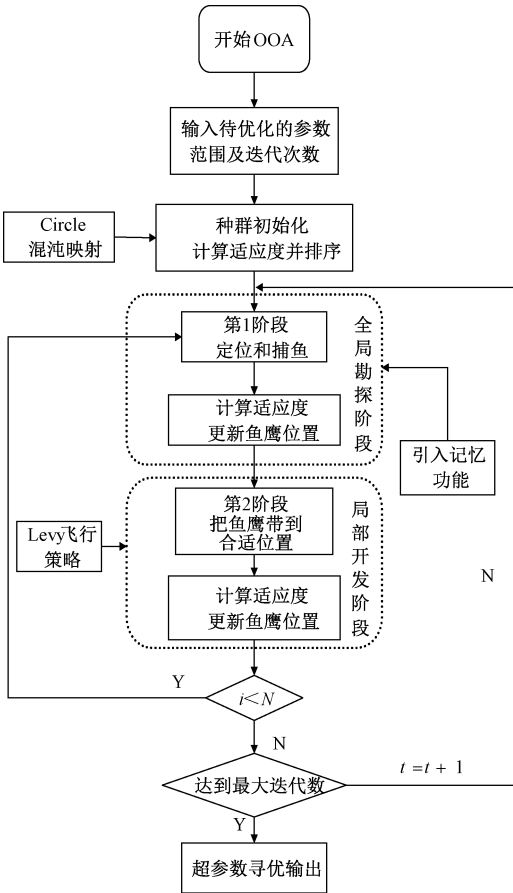


图 6 改进鱼鹰算法流程

Fig. 6 Flow chart of improved Osprey algorithm

3.3 IOOA 性能测试

选取蜣螂优化算法 (DBO)、鲸鱼优化算法 (WOA)、鹈鹕优化算法 (POA)、麻雀搜索算法 (SSA)、OOA 和 IOOA 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 30 和 1 000。为降低实验结果的随机误差影响, 选用 CEC2005 三个标准测试函数测试 ($F1$ 、 $F2$ 、 $F3$)

重复执行 10 次独立实验后, 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, 测试函数如表 1 所示, 测试函数适应度曲线如图 7 所示, 数据结果如表 2 所示。

表 1 标准测试函数

Table 1 The standard test function

函数名称	函数	搜索范围
$F1$	$f_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$
$F2$	$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$
$F3$	$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	$[-100, 100]$

结合表 2 和图 7 可以看出, 在 6 种优化算法中, WOA 和 IOOA 在函数 $F1$ 上的适应度都达到最优, 但 IOOA 的训练迭代次数更少, 而在函数 $F2$ 和 $F3$ 六个算法均未达到理论值, 但和其他 5 种算法相比, IOOA 寻优结果更加接近理论值。综上所述, 经过多策略融合改进的 IOOA 算法, 具有较好的搜索和较快的收敛能力, 有助于提升后续故障诊断模型的准确率。


4 基于 IOOA 优化 GASF-RP-GRU-ViT 故障诊断模型

4.1 故障诊断流程


本文将一维时序信号和两组不同的二维图像进行多模态特征融合, 克服在单一模态情况下模型对特征筛选不完全的问题, 首先将原始故障信号分别利用 GASF 和 RP 实现时序信号图像化, 设计双支路 ViT 有效地学习两组二维图像的空间特征和局部模式。GASF 图像捕捉全局趋势, RP 图像突出局部非线性特征, 两者结合丰富了特征空间, 实现全局与局部、线性与非线性特征的互补。然后通过 GRU 捕获一维时序信号中的动态变化和趋势。将 GRU 与全新的双支路 ViT 并行结合。同时为进一步优化模型, 利用改进鱼鹰优化算法对 GRU 单元数、学习率、MSA 和 ViT 层数等关键超参数进行调优, 增强模型的构建质量。最后在输出层前引入双向长短期记忆网络能够有效获取双向时序依赖关系, 进一步提升模型对故障模式的捕捉能力, 实现更为精确的故障分类。总设计模型如图 8 所示。

4.2 特征融合


在多模态特征融合过程中, GRU 支路、GASF-ViT 支路和 RP-ViT 支路的协同设计实现了优势互补: GRU 时序建模擅长捕捉振动信号的动态演变特征, 但难以表征信号的全局周期性模式; GASF 成像虽能有效保留信号的长期时序关联性, 但对瞬态冲击特征的敏感性不足; 而



(a) 函数 F_1 收敛曲线
(a) Convergence curve of function F_1



(b) 函数 F_2 收敛曲线
(b) Convergence curve of function F_2



(c) 函数 F_3 收敛曲线
(c) Convergence curve of function F_3

图 7 函数 F_1 、 F_2 、 F_3 收敛曲线

Fig. 7 Convergence curves of functions F_1 , F_2 and F_3

频域特征的表达能力有限。正是由于这三种表征方式各具特点又存在互补性,本文通过 GRU-GASF-RP-ViT 的多模态融合架构,既能利用 GRU 捕捉时序动态,又能通过 GASF 和 RP 从不同角度刻画信号的时空特征。

然而,这种多模态融合可能导致特征信息冗余或冲突,例如时序信号的瞬时突变与图像中的周期性纹理特征矛盾、不同模态同时捕捉相同低频信息导致信息重叠。为缓解此问题本文通过层级注意力 (hierarchical attention, HAT) 自适应设计实现特征融合:

先对图像特征进行模态内注意力融合,对齐 GASF 与 RP 图像的特征空间,提取互补性纹理信息如下:

$$F_{img} = MSA(F_g, F_r) = \text{softmax}\left(\frac{F_g W_Q (F_r W_K)^T}{\sqrt{d}}\right) F_r W_V \quad (33)$$

式中: F_g 、 F_r 为 GASF 与 RP 图像特征; F_{img} 为图像融合特征。GASF 特征映射为查询向量; RP 特征映射为键值向量。

再以时序特征为查询向量,自适应聚合图像混合特征中的判别性模式。通过分层细化策略逐步消除冗余特征公式如下:

$$F_{fused} = MSA(F_t, F_{img}) \quad (34)$$

式中: F_t 为时序特征; F_{fused} 为多模态融合特征。

5 实验方案及结果对比分析

5.1 实验装置

万能式断路器故障诊断实验平台如图 9 所示,包含万能式低压断路器、加速度传感器、示波器、可控电源及上位机等部分。ACB 主要型号为 RGW1-3200 型低压万能式断路器。为了测量断路器机械故障时的振动信号更加准确,将加速度传感器通过螺母安装在在断路器外壁。

为了保证故障信号样本的充分采集,本文进行多次故障模拟实验。实验中,首先通过 RS485 通信将智能控制器与上位机分合闸软件与进行连接,利用上位机向 ACB 发出的分合闸指令。根据 DHO4800 示波器以及厂商提供的驱动程序和数据采集软件,可对传感器采集的各种样本信号进行数据存储和远程控制,其中示波器时基设置为 50 ms,采样率设置 20 kSa/s,存储深度为 10 kB,后期通过筛选有效波段样本,将每种振动波形截取为 4 000 个数据点,以便后续模型训练。

本文人为模拟设置了 6 种典型机械故障如表 3 所示,分别采集 ACB 在正常状态,底座松动、合闸不彻底、机械结构卡涩^[22] 6 种合闸状态下的振动信号,每种状态 100 组,共计 600 个样本。采集得到的 6 种合闸状态时序信号如图 10 所示。

表 2 不同算法测试函数寻优结果对比

Table 2 Comparison of the optimization results of different algorithm test functions

函数名	指标	IOOA	OOA	WOA	DBO	POA	SSA
F1	最优值	0	1.48×10^{-281}	0	6.78×10^{-281}	1.65×10^{-275}	2.94×10^{-275}
	平均值	0	2.64×10^{-280}	0	8.21×10^{-280}	2.32×10^{-274}	6.32×10^{-273}
	标准差	0	1.02×10^{-280}	0	6.22×10^{-279}	1.23×10^{-274}	3.23×10^{-273}
F2	最优值	2.76×10^{-255}	2.03×10^{-197}	3.12×10^{-104}	2.33×10^{-255}	3.01×10^{-120}	3.64×10^{-104}
	平均值	6.44×10^{-254}	6.23×10^{-196}	7.43×10^{-102}	6.37×10^{-253}	3.29×10^{-118}	3.98×10^{-103}
	标准差	7.34×10^{-253}	1.24×10^{-196}	3.23×10^{-101}	2.42×10^{-253}	8.38×10^{-117}	5.28×10^{-102}
F3	最优值	3.28×10^{-310}	5.64×10^{-248}	3.68×10^{-209}	7.32×10^{-242}	1.64×10^{-230}	4.66×10^{-170}
	平均值	6.48×10^{-308}	7.93×10^{-247}	2.49×10^{-208}	6.48×10^{-241}	8.48×10^{-228}	2.84×10^{-169}
	标准差	2.58×10^{-307}	9.33×10^{-247}	6.84×10^{-208}	3.23×10^{-240}	4.62×10^{-226}	7.94×10^{-168}

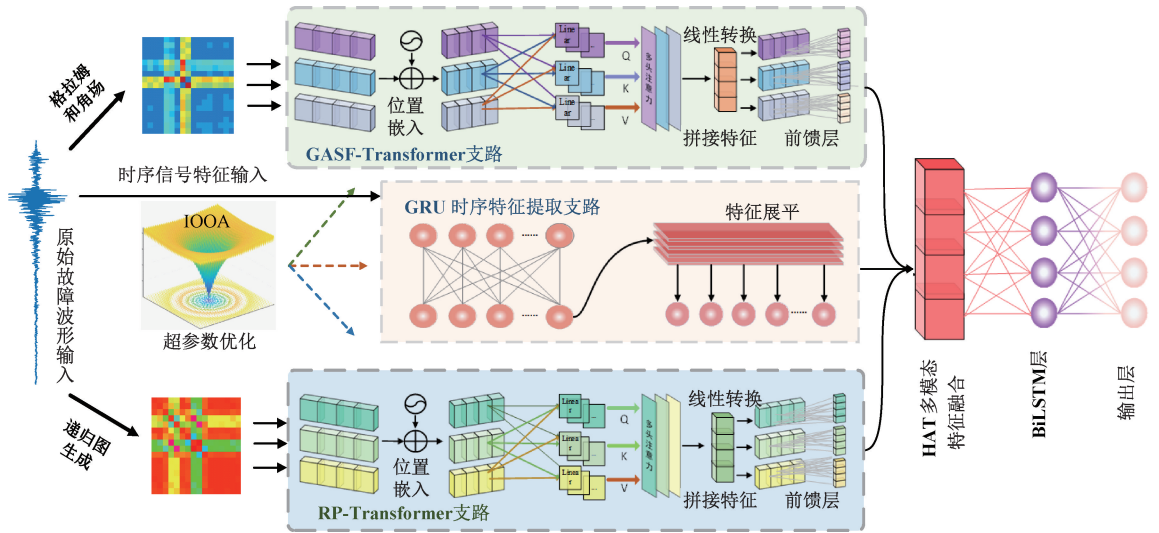


图 8 基于 IOOA 优化的 GASF-RP-GRU-ViT 故障诊断模型

Fig. 8 GASF-RP-GRU-ViT fault diagnosis model optimized based on IOOA

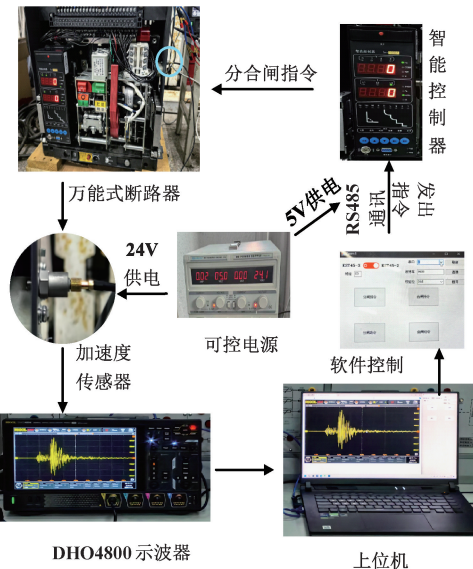


图 9 万能式断路器实验模拟图

Fig. 9 ACB experiment simulation diagram

表 3 实验故障类型

Table 3 Types of experimental faults

	故障类型	故障模拟方法	样本数量
1	正常情况		100
2	底座螺丝松动	拧松底座螺栓	100
3	合闸不彻底	橡胶垫圈放合闸处	100
4	机械结构卡涩	连杆处加入小木棒	100
5	复合故障 I	模拟 2+3	100
6	复合故障 II	模拟 2+4	100

由图 10 可以看出,故障波形与正常状态下的波形还是存在振幅等变量上的差异,但仅仅通过这些差异难以直接判断某一故障的工况。所以要从波形中提取出关键信息进行特征比对,将故障信息明显化,提高识别的效率和准确性。

5.2 数据处理

为了验证故障诊断模型的准确性,对 6 种工况下的样本数据进行处理,将每种工况的 100 个样本按 8 : 2 的




图 10 六种合闸振动信号波形

Fig. 10 Six wave forms of closing vibration signals

比例划分为训练集和测试集。随后,采用优化后的 GRU-GASF-RP-ViT 模型对划分后的数据集进行训练与测试。本文模型仿真结果如图 11 所示。

真实所属类别	1	20 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	19 15.8%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	95.0% 5.0%
	3	0 0.0%	0 0.0%	20 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	20 16.7%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 16.7%	0 0.0%	100% 0.0%
	6	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	19 15.8%	95.0% 5.0%
			100% 0.0%	95.0% 5.0%	100% 0.0%	100% 0.0%	100% 0.0%	95.0% 5.0%
		预测输出类别						
		1	2	3	4	5	6	

图 11 混淆矩阵

Fig. 11 Confusion matrix

从图 11 可以看出,IOOA 优化 GRU-GASF-RP-ViT 的模型在万能式断路器故障诊断准确率高达 98.3%。特别对于正常状态、复合故障 I、机械结构卡涩、合闸不彻底故障类型,模型能够完全正确诊断这 4 类故障,综合结果表明,本文所提模型在断路器故障诊断中较强的故障识别能力,能够有效地识别不同类型的故障模式。

5.3 可视化分析

为进一步验证特征融合的准确性,利用 t-SNE^[23] 对特征向量进行数据降维,将融合后的特征向量映射至二维空间中,降维结果的空间分布情况如图 12 所示。




图 12 t-SNE 分类可视化

Fig. 12 t-SNE classification visualization

由图 12 可知,经 t-SNE 降维后,同一状态的样本表现出了明确的聚类特征,而不同状态的样本在 t-SNE 的映射结果中被分开,形成了不同紧密的簇,不同故障类别更清晰可分,从而证明本文模型特征融合方法有效解决了特征冲突或冗余的问题。

5.4 噪声干扰对比实验

在实际工业生产环境中,断路器通常处于复杂的操作条件下,传感器在采集振动信号过程中,易受到环境噪声干扰,从而产生误差,为验证实验模型在噪声环境下的稳定性,实验采集的振动信号测试集中注入不同信噪比^[24](signal-to-noise ratio, SNR)的高斯白噪声,同时将本文模型与其他模型进行对比。噪声水平覆盖典型工业场景 0~20 dB, SNR 公式如下:

$$SNR = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (35)$$

式中: P_{signal} 、 P_{noise} 分别代表原始信号的功率与噪声功率。各模型不同信噪比下的故障诊断准确率如表 4 所示。

表 4 不同信噪比下各模型诊断准确率

模型	0 dB	5 dB	10 dB	15 dB	20 dB	无噪
1D-GRU	61.7	69.7	75.0	79.3	83.3	85.0
GASF-GRU-ViT	72.1	79.3	86.1	90.2	93.2	95.8
RP-GRU-ViT	74.4	79.7	83.6	85.4	87.9	90.0
MMFNet	74.9	81.0	86.5	89.4	91.7	95.0
本文模型	78.9	84.7	90.3	95.8	97.1	98.3

实验结果表明,在 0 dB 低信噪比环境中,本文模型凭借多模态融合策略展现出显著抗噪优势,准确率达到 78.9%,较纯时序模型提升 17.2%。这一优势主要得益于 RP 对信号相位变化的独特敏感性,在 0 dB 环境下,RP 抗噪性能优于 GASF 2.3%。随着信噪比提升至工业典型工况水平 (SNR ≥ 15 dB),所有模型性能逐渐接近无噪声环境下的表现,其中本文模型达到 97.1% 的准确率,与无噪声条件下的 98.3% 仅有微小差距。这些结果充分验证了多模态特征融合通过互补信息整合来增强系统鲁棒性的有效性,为复杂噪声环境下的断路器故障诊断提供了可靠的技术方案。

5.5 优化算法对比

为验证优化算法对模型性能的提升效果,在固定 GRU-ViT 模型结构的前提下,分别采用 PSO、SSA、DBA、OOA、IOOA 进行超参数优化,并与未优化参数的基准 GRU-ViT 模型进行对比实验,统计各优化方法下的故障诊断平均准确率如表 5 所示。

表 5 不同算法优化模型性能比较。

Table 5 Comparison of the performance of the models

模型	故障诊断平均准确率/%
GRU-ViT	75.7
PSO-GRU-ViT	84.3
SSA-GRU-ViT	87.7
DBA-GRU-ViT	89.3
OOA-GRU-ViT	91.7
IOOA-GRU-ViT	98.3

经改进后的 IOOA-GRU-ViT 模型较其他算法优化和未优化模型准确率提高了 6.6%~22.6%。对于故障诊断任务而言,准确率的提升意味着在实际应用中能够更可靠地识别故障,减少潜在的风险和损失。因此,本文模型在 ACB 机械故障诊断中的高准确率使其成为了更优的选择。

5.6 模型对比

为更加体现本文提出的故障诊断模型的性能优势,分别与 3 组单模态消融模型,其他 3 组 SOTA 模型 AMDC-CNN^[25]、Res2Net^[26]、MMFNet^[27] 进行对比,为确保评估的一致性,试验在相同数据集上执行。得到不同模型混淆矩阵如图 13 所示,整理得出故障分类平均准确率如图 14 所示。

分析图 14 数据可知,GASF-GRU-ViT、RP-GRU-ViT 单图像通道模型将一维时序信号转变二维图像时,由于特征转换过程的不完全,导致它们在某些特征提取上存在遗漏。1 D-GRU 该模型仅依赖于时序信号特征,未能利用二维图像转换时产生的丰富信息,从而丢失信号中的复杂特征,表现相对较差。此外,与当前主流诊断模型 (SOTA) 相比,本文模型同样展现出明显优势,其准确率分别比 AMDC-CNN、Res2Net 和 MMFNet 高出 5.0%、1.6% 和 3.3%。综合来讲,所提模型在特征提取与模态融合方面具有明显优势,在 ACB 故障诊断中能够表现出更好的准确性。

6 结论

本文针对万能式断路器故障诊断准确率不足的问题,创新性地提出了一种基于 IOOA 优化的 GASF-RP-GRU-ViT 多模态融合诊断方法,并成功应用于万能式断路器机械故障诊断领域。该研究通过将振动信号时序特征与 GASF、RP 两种图像特征进行深度融合,突破了传统单一模态诊断方法的性能。同时,针对模型的构建效率,引入 IOOA 对模型中 GRU 单元数、学习率、MSA 层数等超参数进行调优,进一步提升了分类性能。最后搭建故障模拟实验平台,与传统单模态方法和主流诊断模型相比,准确率提升 3.3%~13.3%。满足万能式断路器故障

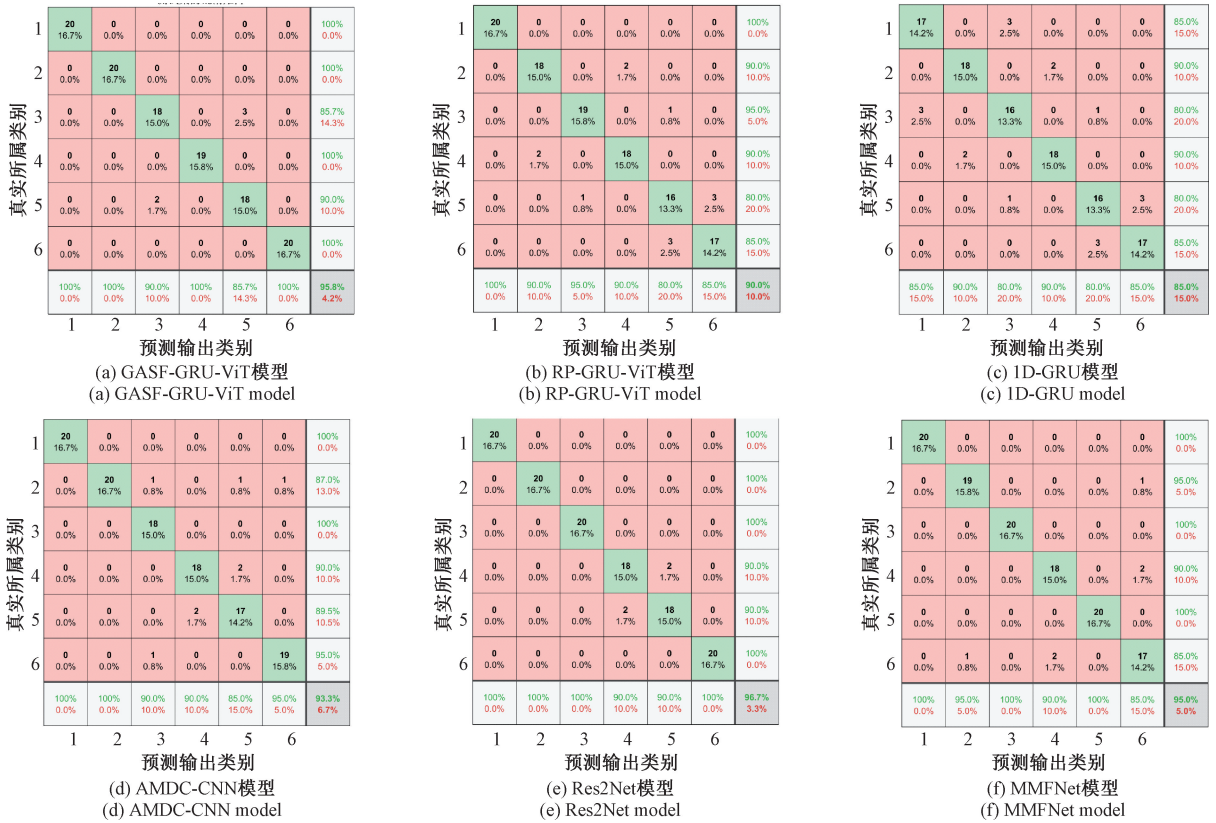


图 13 各模型测试结果
Fig. 13 Test results of each model




图 14 各模型准确率比较

Fig. 14 Comparison of accuracy of each model

的识别要求。但需要指出的是,受限于现有实验装置的安全性要求,本研究主要针对机械故障开展分析,对触头烧蚀等电气故障的诊断仍需进一步探索。未来研究将融合电流、温度等多物理量信号,建立更全面的故障表征

体系。

参考文献

[1] 刘亚魁,李红运,林天然,等. 基于机器视觉的高压断路器机械特性测量方法[J]. 电工技术学报, 2023, 38(S1): 222-230.
LIU Y K, LI H Y, LIN T R, et al. Measurement method of mechanical properties of high voltage circuit breakers based on machine vision [J]. Journal of Electrical Technology, 2023,38 (S1): 222-230.

[2] LU Y, LI Y. A novel fault diagnosis method for circuit breakers based on optimized affinity propagation clustering[J]. International Journal of Electrical Power & Energy Systems, 2020, 118: 105651.

[3] ZHANG H Y, XIE Y Z, YI T Q, et al. Fault detection for high-voltage circuit breakers based on time-Frequency analysis of switching transient E-fields [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1620-1631.

[4] 马莉,霍耀佳,吴杨,等. 基于VMD和KFCM-SVM的高压断路器声振联合故障诊断方法[J]. 高压电器, 2024, 60(8): 53-62.
MA L, HUO Y J, WU Y, et al. A combined acoustic-

- vibration fault diagnosis method for high-voltage circuit breakers based on VMD and KFCM-SVM [J]. *High-Voltage Electrical Appliances*, 2024, 60 (8): 53-62.
- [5] 范兴明, 许洪华, 张思舜, 等. 基于 IDBO-DHKELM 的高压断路器故障诊断研究[J/OL]. *电工技术学报*, 1-12[2025-11-06].
FAN X M, XU H H, ZHANG S SH, et al. Research on fault diagnosis of high-voltage circuit breakers based on IDBO-DHKELM [J/OL]. *Journal of Electrical Technology*, 1-12[2025-11-06].
- [6] 宋金波, 刘锦玲, 闫荣喜, 等. 基于 VMD-1DCNN-GRU 的轴承故障诊断[J]. *吉林大学学报(信息科学版)*, 2025, 43 (1): 34-42.
SONG J B, LIU J L, YAN R X, et al. Bearing fault diagnosis based on VMD-1DCNN-GRU [J]. *Journal of Jilin University (Information Science Edition)*, 2025, 43 (1): 34-42.
- [7] 鄢仁武, 林穿, 高硕勋, 等. 基于小波时频图和卷积神经网络的断路器故障诊断分析[J]. *振动与冲击*, 2020, 39(10): 198-205.
YAN R W, LIN CH, GAO SH X, et al. Fault diagnosis and analysis of circuit breakers based on wavelet time-frequency diagram and convolutional neural network [J]. *Vibration and Shock*, 2020, 39 (10): 198-205.
- [8] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和 MTL-SEResNet 的断路器故障程度评估[J]. *仪器仪表学报*, 2022, 43(6): 162-173.
SUN SH G, ZHANG T T, WANG J Q, et al. Evaluation of circuit breaker fault degree based on continuous wavelet transform and MTL-SERESNet [J]. *Instruments Journal*, 2022, 43 (6): 162-173.
- [9] 司江宽, 吐松江·卡日, 范想, 等. 基于 SO-PAA-GAF 和 AdaBoost 集成学习的高压断路器故障诊断[J]. *电力系统保护与控制*, 2024, 52(3): 152-160.
SI J K, TUSONGJIANG K R, FAN X, et al. Fault diagnosis of high voltage circuit breaker based on SO-PAA-GAF and AdaBoost integrated learning [J]. *Power System Protection and Control*, 2024, 52(3): 152-160.
- [10] 樊红卫, 马宁阁, 马嘉腾, 等. 基于 EMDPWVD 时频图像和改进 ViT 网络的滚动轴承智能故障诊断[J]. *振动与冲击*, 2024, 43(11): 246-254.
FAN H W, MA N G, MA J T, et al. Intelligent fault diagnosis of rolling bearings based on EMDPWVD time-frequency image and improved ViT network [J]. *Vibration and Shock*, 2024, 43 (11): 246-254.
- [11] 李斌, 阎君宇. 基于 GAF-CNN 的弓网电弧识别方法研究[J]. *电子测量与仪器学报*, 2022, 36(1): 188-195.
LI B, YAN J Y. Research on arc recognition method based on GAF-CNN [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36 (1): 188-195.
- [12] 丁伟, 宋俊材, 陆思良, 等. 基于多通道信号二维递归融合和 ECA-ConvNeXt 的永磁同步电机高阻接触故障诊断 [J]. *电工技术学报*, 2024, 39 (20): 6397-6408.
DING W, SONG J C, LU S L, et al. High-resistance contact fault diagnosis of PMSM based on multi-channel signal two-dimensional recursive fusion and ECA-ConvNeXt [J]. *Journal of Electrical Technology*, 2024, 39 (20): 6397-6408.
- [13] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale [J]. *ArXiv preprint arXiv: 2010.11929*, 2021.
- [14] 乔琦, 王红军, 马康, 等. 基于改进的 DenseNet-ViT 联合网络和迁移学习的燃气轮机转子故障诊断[J]. *电子测量与仪器学报*, 2024, 38 (11): 40-47.
QIAO Q, WANG H J, MA K et al. Gas turbine rotor fault diagnosis based on improved DenseNet-Vit joint network and transfer learning [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38 (11): 40-47.
- [15] 刘华咏, 黄聪, 金汉均. 注意力增强的视觉 Transformer 图像检索算法[J]. *电子测量技术*, 2023, 46(23): 50-55.
LIU H Y, HUANG C, JIN H J. Attention-enhanced visual Transformer image retrieval algorithm [J]. *Electronic Measurement Technology*, 2023, 46 (23): 50-55.
- [16] ZHAO Z, HAO K, LIU X, et al. MCANet: Hierarchical cross-fusion lightweight transformer based on multi-ConvHead attention for object detection[J]. *Image and Vision Computing*, 2023, 136: 104715.
- [17] OZANICH E, GERSTOFT P, NIU H. A feedforward neural network for direction-of-arrival estimation[J]. *The Journal of the Acoustical Society of America*, 2020, 147(3): 2035-2048.
- [18] MENARY S, KASKI S, FREITAS A. Transformer normalisation layers and the independence of semantic subspaces [J]. *ArXiv preprint arXiv: 2406.17837*, 2024.
- [19] DEGHANI M, MONTAZERI Z, TROJOVSKÁ E, et al. Coati optimization algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems[J]. *Knowledge-Based Systems*, 2023, 259: 110011.

- [20] 黄子介, 代永强. 多策略融合的斑马优化算法[J]. 国外电子测量技术, 2024, 43(9): 59-68.
HUANG Z J, DAI Y Q. Multi-strategy fusion zebra optimization algorithm [J]. Foreign Electronic Measurement Technology, 2024, 43 (9): 59-68.
- [21] YAO L, YANG J, YUAN P, et al. Multi-strategy improved sand cat swarm optimization: Global optimization and feature selection [J]. Biomimetics, 2023, 8(6): 492.
- [22] 孙曙光, 杨飞龙, 陈静, 等. 基于振动-电流广域特征与软共享机制的断路器多故障诊断[J]. 仪器仪表学报, 2024, 45(1): 46-59.
SUN SH G, YANG F L, CHEN J, et al. Multi-fault diagnosis of circuit breakers based on vibration-current wide-area characteristics and soft sharing mechanism [J]. Chinese Journal of Scientific Instrument, 2024, 45 (1): 46-59.
- [23] FU Y, ZHOU K, ZHU G, et al. A partial discharge signal separation method applicable for various sensors based on time-frequency feature extraction of t-SNE[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-9.
- [24] 张锐, 刘婷婷, 王燕, 等. 基于 FBSE-ESEWT 的齿轮故障诊断方法[J]. 电子测量与仪器学报, 2025, 39(4): 234-246.
ZHANG R, LIU T T, WANG Y, et al. Gear Fault Diagnosis Method based on FBSE-ESEWT [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 234-246.
- [25] WANG D, LI Y, JIA L, et al. Novel three-stage feature fusion method of multimodal data for bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [26] MOU Z, HAN X, FU B, et al. Fault diagnosis method of the USV based on improved Res2Net multiscale feature fusion[J]. IEEE Sensors Journal, 2024, 24 (15): 24892-24904.
- [27] ZHANG Y, FENG K, MA H, et al. MMFNet;

Multisensor data and multiscale feature fusion model for intelligent cross-domain machinery fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.

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, M. Sc. degree, and Ph. D. degree from Liaoning Technical University in 2003, 2006 and 2012, 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.



王志鹏 (通信作者), 2023 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, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。
E-mail: 321363244@qq.com

Wang Zhipeng (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



王幸之, 2023 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, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。
E-mail: 1361200328@qq.com

Wang Xingzhi received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.