

基于 GAF 与并行混合网络的隔离开关 机械故障诊断方法

申张亮¹, 许洪华¹, 陈旖旎¹, 尹来宾¹, 董媛^{2*}, 马宏忠²

(1. 国网江苏省电力有限公司 南京供电分公司, 江苏 南京 210019;

2. 河海大学 电气与动力工程学院, 江苏 南京 211100)

Mechanical Fault Diagnosis Method for Disconnectors Based on GAF and Parallel Hybrid Networks

SHEN Zhangliang¹, XU Honghua¹, CHEN Yini¹, YIN Laibin¹,

DONG Yuan^{2*}, MA Hongzhong²

(1. Nanjing Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China;

2. School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: [**Objective**] To achieve high-precision identification of mechanical faults in disconnectors, a parallel hybrid network incorporating attention mechanisms is proposed, which combines temporal and image features for intelligent diagnosis. [**Methods**] To fully exploit the feature information of dual-channel data, a bidirectional long short-term memory network was employed in the temporal channel to extract time-domain features from vibration signals, capturing the dynamic temporal variations of the signal and effectively reflecting the time-varying characteristics of mechanical faults. In the image channel, vibration signals were converted into two-dimensional images using Gramian angular fields, where polar coordinate mapping was utilized to preserve the temporal dynamics. A convolutional neural network was then used to extract key image features. Furthermore, a self-attention mechanism was introduced in the temporal channel and a channel attention mechanism in the image channel, enabling the model to adaptively adjust the weight of each channel, thereby emphasizing critical information and effectively reducing feature redundancy.

[**Results**] Fault simulation experiments were conducted on GW4-126 type disconnectors, and vibration signals under four operating conditions were collected. The proposed method was compared with five other deep learning models. Experimental

results demonstrated that the proposed method achieves a fault recognition accuracy exceeding 97%, effectively identifying typical mechanical faults such as mechanism jamming, looseness, and phase asynchrony. [**Conclusion**] The proposed parallel hybrid model overcomes the limitations of single-channel approaches by integrating two distinct types of feature information. The introduction of attention mechanisms enables the model to dynamically adjust weights, highlight salient features, and enhance the accuracy of fault identification. This method provides a reliable theoretical foundation and technical reference for the condition monitoring of disconnectors, holds significant potential for future fault diagnosis and equipment maintenance, and offers new insights for the development of smart grid technologies.

Key words: disconnector; mechanical fault; fault diagnosis; vibration signal; Gramian angular field; convolutional neural network; attention mechanism

摘要: [**目的**] 为了实现对隔离开关机械故障的高精度识别,提出了一种融合注意力机制的并行混合网络,结合时序与图像特征进行智能诊断的方法。[**方法**] 为充分利用双通道数据的特征信息,时序通道采用双向长短期记忆网络提取振动信号的时域特征,捕捉信号的时间动态变化,充分反映机械故障的时变特征;图像通道通过格拉姆角场将振动信号转换为二维图像,利用极坐标映射保留信号的时间动态特性,然后利用卷积神经网络提取关键图像特征。此外,两通道分别引入自注意力机制和通道注意力机制,能够自适应地调整每个通道的权重,从而突出关键信息,并有

基金项目: 国网江苏省电力有限公司重点科技项目资助 (J2024047)

Funded by the Key Technology Project of State Grid Jiangsu Electric Power Co., Ltd. (J2024047)

效减少特征冗余。【结果】针对 GW4-126 型隔离开关进行故障模拟试验,采集 4 种状态下的隔离开关振动信号,将本文所提故障诊断方法与其他 5 种深度学习模型相比。试验结果表明,本文所提方法的故障识别准确率超过 97%,能够精确识别隔离开关的机构卡涩、松动及三相不同期等典型机械故障。【结论】本文提出的并行混合模型通过融合两种不同特征信息,克服了单一通道方法的局限性;通过引入注意力机制,模型能够更好地动态调整权重,突出关键特征,提高故障识别的精度和准确性。该方法为隔离开关的状态识别提供了可靠的理论依据和技术参考,对于未来的故障诊断和设备维护具有重要的应用价值,并为智能电网技术的发展提供了新的思路。

关键词: 隔离开关;机械故障;故障诊断;振动信号;格拉姆角场;卷积神经网络;注意力机制

0 引言

电力设备智能化运维是实现电网智能化发展的关键环节。作为电力系统中广泛使用的一次设备,隔离开关长期运行于复杂多变的户外环境,频繁遭受强降雨、大雪和高温等极端气象条件的侵袭^[1-3],这极易诱发其机械部件故障。据统计,隔离开关总故障率约为 4%,而机械故障占比高达 70%,已成为威胁电网安全稳定运行的主要故障类型^[4]。当前主流检修模式依赖定期检修,其状态评估过程过度依托运维人员的主观经验,存在评估标准模糊、客观性与可操作性不足等显著问题。因此,基于先进状态监测技术的隔离开关机械缺陷精准识别与故障诊断研究,对于提升设备运行可靠性、保障电网安全运行具有至关重要的意义,同时为实现电网智能化发展目标提供了关键支撑。

隔离开关的故障诊断涉及多个信号源和技术手段,目前主要从机械特性、电气特性和材料特性 3 个维度进行分析。通过采集振动^[5-6]、操作力矩^[7-8]、转角^[9]和姿态^[10]等信号,并结合算法实现机械故障的识别。近年来,激光雷达技术凭借其高精度和实时性在姿态监测领域得到了广泛关注^[10],但由于其高成本和易受电磁干扰的限制,尚未在实际设备中得到广泛应用。触头氧化导致接触电阻增加,引发过热或电弧放电,进而加剧绝缘材料劣化。因此,电气和材料故障常通过电流暂态信号^[11]或红外热成像^[12]进行诊断,温度监

测和红外成像适用于早期故障检测,但其诊断时效性较低;振动信号分析由于其成熟度和低成本,仍是故障诊断中的常用方法^[13-17]。文献[18]通过自适应鲸群优化变分模态分解提取振动信号能量熵,并用 AdaBoost-支持向量机(Support Vector Machine, SVM)分类。文献[19]提出基于多路振动信号融合的诊断方法,结合 Relief 算法优化特征权重后,采用 SVM 分类。文献[20-21]结合振动、电流及力矩信号,构建时频域多模态特征,利用 SVM 或深度学习进行融合分类。因此通过外嵌式振动传感器,可以在无需改动设备结构的前提下,以非介入方式采集数据,从而实现快速监测与潜在隐患的有效预警。

近年来深度学习在图像分类领域的快速发展为隔离开关的智能化诊断提供了新思路。文献[22]提出了一种结合格拉姆角场(Gramian Angular Field, GAF)与卷积神经网络(Convolutional Neural Network, CNN)的轴承故障诊断模型,但未充分考虑信号的时间序列预测能力。文献[23-24]均基于 GAF 结合深度学习对变压器绕组松动故障进行诊断,结果表明格拉姆角差场(Gramian Angular Difference Field, GADF)在保留时间相关性和提高故障识别准确率方面优于格拉姆角和场(Gramian Angular Summation Field, GASF),为振动信号的智能化诊断提供了重要技术支撑。文献[25]提出了一种结合 GAF 与并行 CNN 的逆变器监测与诊断方法,通过融合 GASF 和 GADF 的图像,充分挖掘数据特征以提取更多差异性信息,但未进一步考虑数据特征的互补性。

基于上述分析,本文以 GW4-126 型隔离开关的机构卡涩、松动及三相不同期 3 种典型故障为研究对象,通过振动信号特征分析。诊断模型采用并行混合网络结构;时序通道利用双向长短期记忆(Bidirectional Long Short-Term Memory, BiLSTM)网络从原始振动信号中提取时序特征;图像通道通过 GAF 将振动信号转化为二维图像,利用 CNN 提取图像特征。为充分利用图像特征信息,两通道均引入注意力机制优化特征融合过程。最终,训练数据用于获得最佳诊断模型,测试数据则用于验证模型性能。

1 理论基础

1.1 GAF

GAF 通过将时间序列映射到极坐标系实现图像编码^[26-27], 在保留时间序列特征的同时, 利用格拉姆矩阵中角度的余弦值有效提取序列特征。其实现过程如下。

将时间序列 $X = \{x_1, x_2, \dots, x_n\}$ 的 n 个数据通过式(1)缩放, 使得 n 个数据值都落在区间 $[-1, 1]$ 范围内:

$$\tilde{x}_i = \frac{[x_i - \max(X)] + [x_i - \min(X)]}{\max(X) - \min(X)} \quad (1)$$

式中: \tilde{x}_i 为通过缩放处理后得到的新时间序列中的数据点; x_i 为原始时间序列中的数据点; $\max(X)$ 、 $\min(X)$ 分别为原始时间序列中所有数据点的最大值、最小值。

将 \tilde{x}_i 通过反余弦函数映射到极坐标系下, 如式(2)所示:

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{x} \\ r_i = \frac{i}{n}, i \in n \end{cases} \quad (2)$$

式中: ϕ_i 为经过反余弦函数变换后的极角; r_i 为极径。

为了减少噪声的影响, GAF 定义了两种内积形式, 如式(3)、式(4)所示:

$$\langle x_i, x_j \rangle = \cos(\phi_i + \phi_j) \quad (3)$$

$$\langle x_i, x_j \rangle = \sin(\phi_i - \phi_j) \quad (4)$$

GAF 根据两种不同的内积定义形式生成两种图像, 其数学表达如式(5)、式(6)所示:

$$G_s = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (5)$$

$$G_d = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \sin(\phi_1 - \phi_2) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \sin(\phi_2 - \phi_2) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \sin(\phi_n - \phi_2) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (6)$$

1.2 BiLSTM

BiLSTM 由前向和后向两层 LSTM 组成, 分别顺序和逆序处理序列信息^[28]。每个时间步的输出由前向和后向隐藏层状态连接而成, 融合了上下文特征。相比单向 LSTM, BiLSTM 在处理时间序列数据时能够捕获前后关联特征, 更全面地表征时序信息。其前向和后向 LSTM 的更新如式(7)所示:

$$\begin{cases} \vec{h}_t = \text{LSTM}(x, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{LSTM}(x, \overleftarrow{h}_{t-1}) \\ y_t = \vec{W}\vec{h}_t + \overleftarrow{W}\overleftarrow{h}_t + b_y \end{cases} \quad (7)$$

式中: \vec{h}_t 为前向隐藏层状态; \overleftarrow{h}_t 为后向隐藏层状态; \vec{W} 为前向 LSTM 层到输出层的权重项; \overleftarrow{W} 为后向 LSTM 层到输出层的权重项; b_y 为输出层的偏置项。

1.3 CNN

CNN 是一种典型的深度学习算法, 广泛应用于图像识别、分类和处理等领域, 通常由卷积层、池化层、全连接层和 Softmax 分类层构成^[29-30]。卷积操作的计算式为

$$A_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} k_{ij}^l + b_j^l\right) \quad (8)$$

式中: A_j^l 为第 l 层网络中的第 j 个特征图; f 为非线性激活函数; k_{ij}^l 为第 l 层卷积核的权重; x_i^{l-1} 为第 $l-1$ 层的输入; b_j^l 为偏置量。

在池化层部分, CNN 通过最大池化操作减少特征图的尺寸, 同时保留关键信息, 并降低模型的计算复杂度。最大池化操作的计算式为

$$B_{m,n}^l = \max_{i,j \in W^l} x_{i,j} \quad (9)$$

式中: $B_{m,n}^l$ 为池化后特征图在第 m 行 n 列的元素; W^l 为池化窗口; $x_{i,j}$ 为输入特征图在窗口内对应的特征值。

1.4 注意力机制

为解决 CNN 和 BiLSTM 在处理长操作码序列时的特征提取能力下降、数据缺失及维度爆炸问题, 本文引入注意力机制^[31-33]。通过动态调整两通道中元素的权重, 突出关键信息, 过滤冗余数据, 从而提高漏洞识别的效率与准确性。其具体实现过程如下。

故障特征通过注意力机制层计算得到特征权重系数, 如式(10)所示:

$$\begin{cases} z_i = W_i \cdot p_i + b_i \\ a_i = \tanh(z_i) \end{cases} \quad (10)$$

式中: p_i 为输入特征; W_i 为权重项; b_i 为偏置项; a_i 为经过双曲正切函数处理后的特征权重系数。

基于 Softmax 函数对故障特征权重做动态调整,如式(11)所示:

$$\alpha_i = \frac{e^{a_i}}{\sum_{j=1}^i e^{a_j}} \quad (11)$$

式中: α_i 为特征 i 的权重系数,权重系数的总和为 1,形成一个概率分布。

通过注意力机制对故障特征进行加权融合,可以得到优化后的故障表达 F_c 。如式(12)所示:

$$F_c = \sum_i \alpha_i \cdot p_i \quad (12)$$

式中: F_c 为融合后的特征。

2 故障诊断网络结构设计

2.1 基于并行混合网络的故障诊断模型

本文采用如图 1 所示的并行混合网络结构,

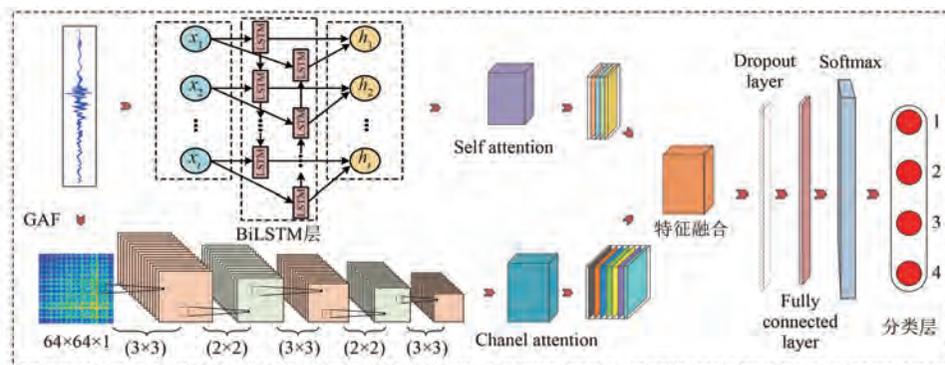


图 1 并行混合网络结构图

Fig. 1 Parallel hybrid network structure diagram

2.2 故障诊断流程

为实现隔离开关机械故障诊断,本文提出了一种基于 GAF 与融合注意力机制的并行混合网络的隔离开关机械故障诊断方法,具体实现流程如图 2 所示,诊断步骤如下。

步骤 1:在 4 种状态下对隔离开关设备进行振动信号的采集。

步骤 2:将采集到的一维振动信号利用 GAF 转化为二维图像,并保留原始时序特征,构建双通道数据集,按 4:1 的比例随机划分为训练集和测试集。

步骤 3:将数据分别输入并行特征提取分支,时序通道通过 BiLSTM 建模时序特征,图像通道

包括图像通道和时序通道。两通道的加权特征在融合层相加后,进入全连接层进一步提取特征,最终通过 Softmax 层进行分类,同时在全连接层加入 Dropout,防止过拟合。

时序通道采用 BiLSTM 网络结构提取一维振动信号的时序特征。时序数据首先通过展平操作,然后进入 BiLSTM 层提取时间序列特征,BiLSTM 层的单元数设置为 128,同时设置输出模式为 last。在 BiLSTM 层之后引入自注意力机制,通过计算时间步之间的相似性,根据相关性动态调整时间步特征的权重。图像通道采用 CNN 结构对 GAF 图像数据进行特征提取。网络结构中包含三层卷积池化模块,卷积核大小均为 3×3 ,每层的卷积核数量分别为 32、64 和 128。卷积步长为 1,激活函数采用 ReLU,同时设置 padding 为 valid,以保持卷积操作后特征图的空间尺寸。池化层的核大小为 2×2 ,步长为 1,采用最大池化操作。最后,在卷积后加入通道注意力,用于对图像特征加权。

通过 CNN 提取图像特征,结合自注意力机制和通道注意力机制增强关键特征。

步骤 4:在融合层将时序和图像通道的加权特征相加,形成多模态特征表示,并输入全连接层完成最终的特征提取和分类映射。

步骤 5:将测试集输入训练好的模型,通过 Softmax 分类器计算每个类别的预测概率,评估故障诊断效果并输出诊断结果。

3 试验结果与分析

3.1 试验方案

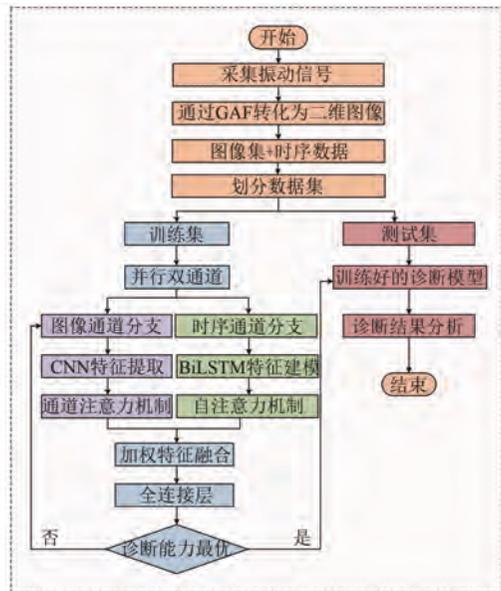


图 2 隔离开关故障诊断流程图

Fig. 2 Disconnector fault diagnosis flow chart

本文以 GW4-126 型隔离开关为研究对象,搭建了如图 3 所示的隔离开关机械故障模拟试验平台。试验中模拟了 3 种典型机械故障:机构卡涩、机构松动和三相不同期。针对机构卡涩,通过在传动机构关节处捆绑橡胶弹性绳以增加机械阻力,从而模拟卡涩状态;针对机构松动,通过适度松动主动极连杆关节螺栓,模拟机械连接松动的特性;针对三相不同期,以 A 相为例,通过调整 A 相从动极拐臂,使 A 相与 B 相、C 相不同期。



图 3 试验数据采集平台

Fig. 3 Experimental data acquisition platform

数据采集系统包括隔离开关、上位机、DH5922D 动态信号采集仪以及 4 个型号为 1A212E 的 IEPE 加速度传感器。加速度传感器布置在隔离开关 A 相左极支架、B 相左极支架、C 相左极支架和 A 相横梁中部 4 个位置,以采集各

类故障状态下的振动数据,支持后续的离线建模与分析,测点布置方案如图 4 所示。

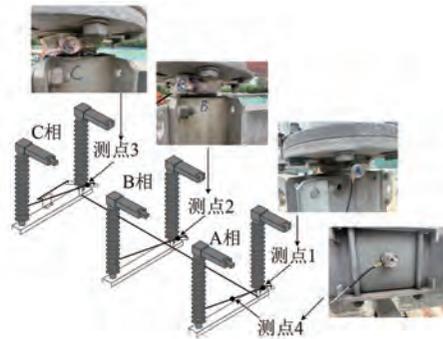


图 4 测点布局示意图

Fig. 4 Schematic diagram of measuring point layout

3.2 生成数据集

本文以变电站隔离开关的振动信号为研究对象,采集其 4 种运行状态下的数据。采样频率设为 20 kHz,单次采样时长为 10 s。基于 4 种测点位置,分别构建包含 4 类状态的数据库,每类状态含 500 组样本,总计 2 000 组样本。将数据集按 4:1 的比例随机划分为训练集和测试集。4 种典型振动信号如图 5 所示,左侧为原始时序数据,右侧为对应的 GAF 图像。从图中可以看出,正常与故障数据样本在颜色深浅和形状纹理上存在明显差异,这些差异使得不同工况下隔离开关机械故障振动信号转换后的图像具有可识别的特征,为 CNN 模型的学习提供了可能性。

3.3 训练与结果展示

使用 GADF 和 GASF 两种编码方式生成图像,并通过并行混合网络分别进行训练。为提升计算效率和特征提取效果,所有图像像素大小在训练前均被调整为 64×64。采用 Adam 优化器进行优化,初始学习速率设定为 0.001。采用分段学习率调整策略,最大迭代次数设定为 100,损失函数采用交叉熵函数,训练环境为 GPU。两种编码方式的分类准确率迭代过程如图 6 所示。

由图 6 可知,两种编码方式在训练集上的分类准确率差异较小,但在测试集上,GADF 的准确率显著优于 GASF。为进一步验证模型的故障诊断性能,本文绘制了基于 GADF 编码图像训练的并行混合网络模型的准确率和损失值曲线,如图 7、图 8 所示。其故障诊断模型的混淆矩阵如图 9 所示,图中横轴和纵轴分别表示实际类别和预测

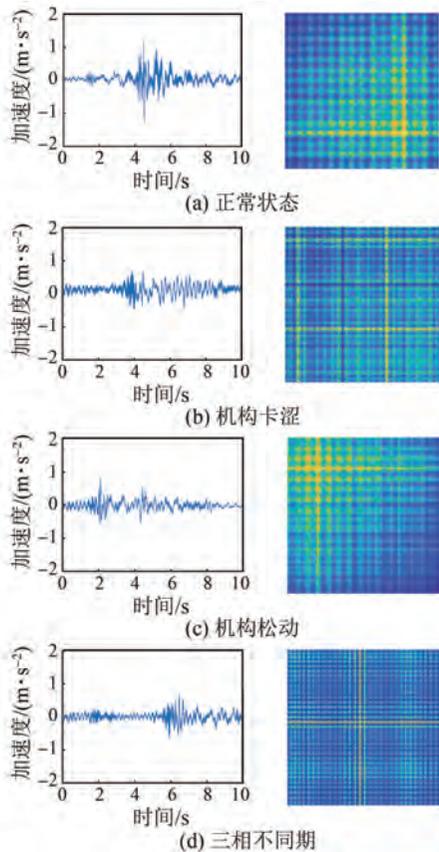


图 5 典型振动信号的波形与 GAF 图像

Fig. 5 Waveforms of typical vibration signals and GAF images

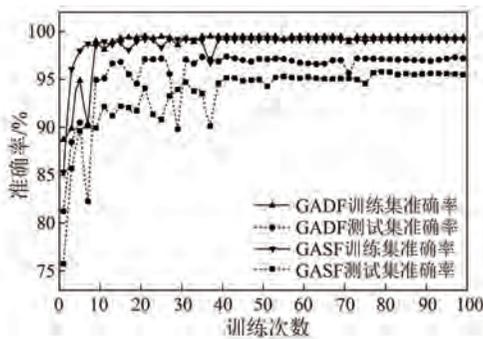


图 6 分类准确率迭代过程

Fig. 6 Classification accuracy iteration process

类别,状态 1 至状态 4 分别对应正常状态、机构卡涩、机构松动和三相不同期。矩阵对角线上的数值反映了各状态的识别准确率。

由图 7、图 8 可知,在迭代 100 次后,本文模型达到收敛状态。训练集分类准确率和损失值收敛至 0.987 和 0.07;测试集的分类准确率和损失值则收敛至 0.975 和 0.17。此外,测试曲线紧跟训练曲线,表明模型并未出现过拟合现象。

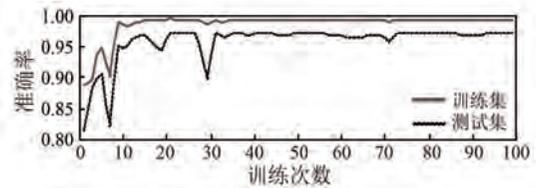


图 7 GADF-准确率曲线

Fig. 7 GADF-accuracy curves

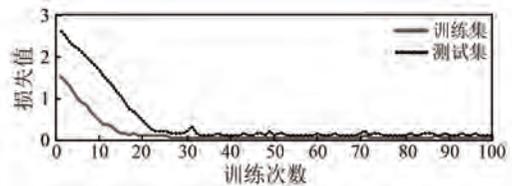


图 8 GADF-损失值曲线

Fig. 8 GADF-loss value curves

混淆矩阵

	状态1	状态2	状态3	状态4		
预测类别	状态1	97 24.25%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	状态2	0 0.0%	97 24.25%	0 0.0%	2 0.5%	98% 2.0%
	状态3	3 0.75%	2 0.5%	100 25.00%	2 0.5%	93.5% 6.5%
	状态4	0 0.0%	1 0.25%	0 0.0%	96 24.00%	99% 1.0%
	97% 3.0%	97% 3.0%	100% 0.0%	96% 4.0%	97.5% 2.5%	
	状态1	状态2	状态3	状态4	实际类别	

图 9 混淆矩阵

Fig. 9 Confusion matrix

由图 9 可知,正常合闸和机构卡涩的分类准确率均为 97%,表明模型能够有效提取这两类状态的特征。机构松动的分类准确率为 100%,充分体现了本文所提方法在该类故障信号上的卓越诊断能力。三相不同期的分类准确率为 96%,尽管存在少量误判,其中 2% 的样本被误判为机构卡涩,另有 2% 被误判为机构松动,但总体分类精度仍然较高。综合分析表明,本文模型在 4 种状态下的总体准确率达到 97.5%,验证了其在多类别信号分类任务中的可靠性与泛化能力。

试验结果表明,本文所提方法具有良好的诊断精度和适用性,为隔离开关机械故障诊断提供了一种可行的技术路径,也为后续相关研究和实际应用提供了理论和实践支持。

3.4 不同模型训练效果对比

为充分验证本文所提诊断方法性能的优越性,设计了 5 种对比模型:单通道图像-CNN、单通道时序-BiLSTM、双通道图像-CNN-BiLSTM、双通道图像-CNN-Attention 以及无注意力机制双通道融合模型。

单通道图像-CNN、单通道时序-BiLSTM 的模型结构和参数配置与 2.1 节中一致。双通道图像-CNN-BiLSTM 模型基于 GADF 和 GASF 两种图像形式进行特征提取与融合,每个通道包含 3 层卷积池化模块与 1 层 BiLSTM 模块,卷积核大小为 3×3 ,卷积核数量分别为 32、64、128,池化核大小为 2×2 ,激活函数为 ReLU, BiLSTM 单元门大小设置为 64,激活函数为 tanh。双通道图像-CNN-Attention 为优化特征提取,在两个 CNN 通道中引入通道注意力机制,通过加权增强关键特征。无注意力机制双通道融合模型是在本文模型的基础上移除所有注意力机制,时序通道和图像通道特征直接在融合层加权相加后输入全连接层进行分类。为确保诊断模型的稳定性并尽量减少偶然因素的影响,所有对比模型均在相同的样本上进行训练和评估。评价指标结果如表 1 所示,训练对比曲线如图 10、图 11 所示。

表 1 不同诊断模型效果对比

Tab. 1 Comparison of diagnostic performance across different models

序号	模型	准确率/%	精确率/%	召回率/%	F1 值/%
1	单通道图像-CNN	90.33	91.50	88.67	90.06
2	单通道时序-BiLSTM	89.87	90.42	87.92	89.15
3	双通道图像-CNN-BiLSTM	93.25	93.67	92.50	93.08
4	双通道图像-CNN-Attention	94.50	94.75	93.83	94.29
5	无注意力机制双通道融合模型	92.58	92.90	91.50	92.20
6	本文模型	97.50	97.67	97.42	97.54

结合表 1 的试验结果可知,单通道图像-CNN 模型仅基于 GADF 提取图像特征,受限于单一模态的特征表征能力,识别准确率为 90.33%。单通道时序-BiLSTM 模型通过 BiLSTM 捕捉时序依赖关系,但由于时序模态特征单一且易受噪声影响,其识别准确率为 89.87%,略低于单通道图像-CNN 模型。双通道图像-CNN-BiLSTM 模型和双通道图像-CNN-Attention 模型均融合了 GADF 和

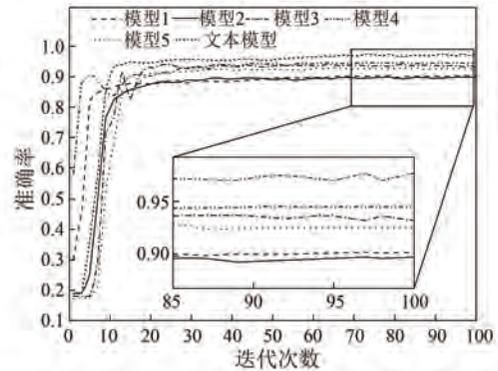


图 10 准确率对比曲线

Fig. 10 Comparison of training accuracy curves

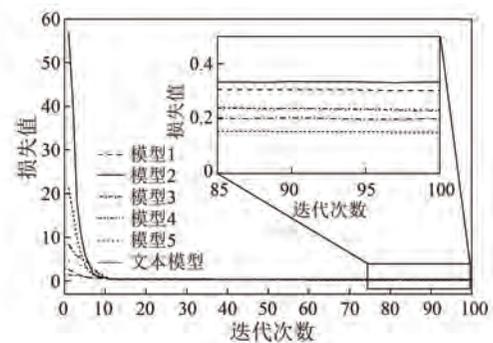


图 11 损失值对比曲线

Fig. 11 Comparison of training loss value curves

GASF 两种图像特征,利用 CNN 提取空间特征,并通过不同方式进一步优化特征提取。双通道图像-CNN-BiLSTM 模型结合 CNN 和 BiLSTM,分别捕捉图像特征与时序关系,识别准确率达到 93.25%;而双通道图像-CNN-Attention 模型在 CNN 提取空间特征的基础上引入通道注意力机制,进一步提升关键特征的权重,识别准确率提高至 94.50%。双通道模型通过融合两种不同特征信息,有效弥补单一通道的局限性,使其在捕捉特征全面性与分类性能方面均有显著提升。无注意力机制双通道融合模型通过简单加权融合图像特征与时序特征,尽管有效整合了双通道特征信息,识别准确率达到 92.58%,但由于缺乏动态优化,其性能相比引入注意力机制的模型略显不足,这说明注意力机制在优化特征提取和提高分类精度方面起到了显著的作用。

本文提出的并行混合网络融合了 GADF 图像与时序数据,采用 CNN 提取空间特征,并利用 BiLSTM 捕捉序列特征,同时结合注意力机制动态调整特征权重,从而弥补单一数据表征方法的局

限性,全面提升数据特征的表达能。在测试集上的分类准确率达到 97.50%,相比其他方法准确率显著提升,同时精确率、召回率和 F1 值均超过 97%,综合评价指标最优。

4 结语

本文提出了一种基于 GAF 与并行混合网络的故障诊断方法,以隔离开关典型机械故障为研究对象,并利用试验平台采集的振动信号,实现了对 4 种状态的全面诊断,得出以下结论。

(1) GADF 图像在故障特征表征中表现出良好的适用性,通过将一维振动信号转化为二维图像,捕捉不同状态下的关键特征,为后续特征提取与分类提供了高质量数据基础。

(2) 并行混合网络结构设计融合了 GAF 图像和时序数据特征,全面提升了故障特征的表达能力和分类性能。

(3) 本文提出双通道并行的动态权重机制,时序通道通过自注意力调整时间权重,图像通道通过通道注意力增强故障纹理表征。同时,为避免训练过程中出现过拟合问题,模型引入了 Dropout 技术,降低了对特定特征的过度依赖,从而显著提升了泛化性能和故障诊断的准确性。

(4) 本文所提方法融合了 GADF 图像、时序信号处理与深度学习模型的优点,相比传统方法更具鲁棒性和泛化能力,能够有效应对隔离开关故障诊断中的复杂性与多样性,具有极大的实际应用潜力。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

申张亮进行了方案设计、内容总结与论文撰写;许洪华进行了试验研究与数据收集;陈旖旎参与了数据分析;尹来宾参与了论文的审核与修改;董媛负责了最终的论文审阅与修改;马宏忠提供了整体指导并参与论文的审核。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summary, and paper writing were carried out by Shen Zhangliang. The experimental research and data collection were conducted by Xu Honghua. Chen Yini participated in data analysis. Yin Laibin participated in the review and revision of the manuscript. Dong Yuan was responsible for the final review and revision of the paper. Ma Hongzhong provided overall guidance and participated in the manuscript review. All authors have read and approved the final version of the paper for submission.

参考文献

- [1] 何成,李文胜,王欣欣,等. 户外隔离开关模拟试验台研制及试验研究[J]. 机械设计, 2018, 35(6): 70-76.
HE C, LI W S, WANG X X, et al. Development and test of outdoor disconnector simulation test platform [J]. Journal of Mechine Design, 2018, 35(6): 70-76.
- [2] 解骞,徐浩岚,王彤,等. 基于自主认知深度时间聚类表示的隔离开关故障诊断方法[J]. 电气工程学报, 2024, 19(1): 281-289.
XIE Q, XU H L, WANG T, et al. Disconnector fault diagnosis method based on autonomous-cognition deep temporal clustering representation [J]. Journal of Electrical Engineering, 2024, 19(1): 281-289.
- [3] 庄小亮,李乾坤,秦秉东,等. 基于 MFCC 和随机森林的 GIS 动作声纹特征辨识和操作机构异常分类[J]. 电机与控制应用, 2024, 51(3): 10-20.
ZHUANG X L, LI Q K, QIN B D, et al. GIS action voiceprint feature identification and operation mechanism anomaly classification based on MFCC and random forest [J]. Electric Machines & Control Application, 2024, 51(3): 10-20.
- [4] 梁守硕. 基于多源信息融合的智能隔离开关机械故障识别系统[J]. 电气应用, 2023, 42(6): 41-47.
LIANG S S. Intelligent isolation switch mechanical failure recognition system based on multi-source information fusion [J]. Electrotechnical Application, 2023, 42(6): 41-47.
- [5] 陈富国,蔡杰,李中旗. 基于长短时记忆网络的高压隔离开关故障诊断研究[J]. 中国测试, 2022, 48(7): 114-119.

- CHEN F G, CAI J, LI Z Q. Study on fault diagnosis of high voltage disconnecter based on long-short term memory network [J]. *China Measurement & Testing Technology*, 2022, 48(7): 114-119.
- [6] 马佳琪, 王丰华, 盛戈峰, 等. 基于同步挤压变换和深度迁移学习的 GIS 隔离开关故障诊断[J]. *电力自动化设备*, 2024, 44(2): 218-224.
- MA J Q, WANG F H, SHENG G H, et al. Fault diagnosis of GIS disconnecter based on synchrosqueezing transform and deep transfer learning [J]. *Electric Power Automation Equipment*, 2024, 44(2): 218-224.
- [7] 曾力勇, 王俊, 张乐萌, 等. 高压隔离开关多体动力学仿真及力矩特性研究[J]. *电工技术*, 2023, (2): 109-115.
- ZENG L Y, WANG J, ZHANG L M, et al. Research on multi-body dynamics simulation and torque characteristics analysis of high-voltage disconnecter [J]. *Electric Engineering*, 2023, (2): 109-115.
- [8] 彭诗怡, 刘衍, 周涛涛, 等. 基于操作力矩的高压隔离开关机械缺陷智能诊断[J]. *电工技术学报*, 2021, 36(7): 1356-1367.
- PENG S Y, LIU Y, ZHOU T T, et al. Intelligent diagnosis technology of mechanical defects of high voltage disconnecter [J]. *Transactions of China Electrotechnical Society*, 2021, 36(7): 1356-1367.
- [9] 关为民, 卞超, 李东风. 基于主轴扭矩-转角特性的高压隔离开关缺陷分析仿真[J]. *高压电器*, 2024, 60(1): 48-54.
- GUAN W M, BIAN C, LI D F. Analysis and simulation of high voltage disconnecter defects based on spindle torque-rotation angle characteristics [J]. *High Voltage Apparatus*, 2024, 60(1): 48-54.
- [10] 李可萌, 陈富国, 杨晖, 等. 基于姿态传感器的高压隔离开关机械故障智能诊断研究[J]. *电网技术*, 2023, 47(9): 3781-3790.
- LI K M, CHEN F G, YANG H, et al. Intelligent diagnosis for mechanical faults of high voltage disconnecter based on attitude sensor [J]. *Power System Technology*, 2023, 47(9): 3781-3790.
- [11] 李旭, 郝建, 李滢, 等. 变频电流激励下 GIS 隔离开关机械缺陷的振动非线性行为及其辨识方法[J]. *高电压技术*, 2024, 50(2): 579-589.
- LI X, HAO J, LI Y, et al. Nonlinear vibration behavior and identification method for GIS disconnecter looseness mechanical defect under variable frequency currents excitation [J]. *High Voltage Engineering*, 2024, 50(2): 579-589.
- [12] 郭双权, 郝欢, 王阳. 基于 HOG 特征的隔离开关红外图像故障识别方法[J]. *红外技术*, 2025, 47(2): 243-249.
- GUO S Q, HAO H, WANG Y. Infrared image fault recognition method for disconnecter based on HOG features [J]. *Infrared Technology*, 2025, 47(2): 243-249.
- [13] 崔星, 陈静, 孙婧琪, 等. 基于 ICEEMDAN 多尺度模糊熵和 MVO-KELM 的变压器绕组铁心机械故障诊断[J]. *电机与控制应用*, 2023, 50(10): 81-90.
- CUI X, CHEN J, SUN J Q, et al. Mechanical fault diagnosis for transformer winding core based on ICEEMDAN multi-scale fuzzy entropy and MVO-KELM [J]. *Electric Machines & Control Application*, 2023, 50(10): 81-90.
- [14] 薛健侗, 马宏忠. 变压器绕组松动故障的混沌特征分析方法[J]. *电机与控制应用*, 2023, 50(10): 76-80+90.
- XUE J T, MA H Z. Chaotic feature analysis method of transformer winding looseness fault [J]. *Electric Machines & Control Application*, 2023, 50(10): 76-80+90.
- [15] 臧旭, 张甜瑾, 邵心悦, 等. 基于时变滤波经验模态分解和 SSA-LSSVM 的变压器内部机械故障诊断方法[J]. *电机与控制应用*, 2023, 50(9): 49-56.
- ZANG X, ZHANG T J, SHAO X Y, et al. A transformer internal mechanical fault diagnosis method based on TVFEMD and SSA-LSSVM [J]. *Electric Machines & Control Application*, 2023, 50(9): 49-56.
- [16] 薛健侗, 马宏忠. 基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断方法[J]. *电机与控制应用*, 2023, 50(9): 57-62.
- XUE J T, MA H Z. Fault diagnosis method of transformer winding looseness based on ST-SVD and WOA-SVM model [J]. *Electric Machines & Control Application*, 2023, 50(9): 57-62.
- [17] 薛健侗, 马宏忠. 基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断[J]. *电机与控制应用*, 2023, 50(8): 84-90.
- XUE J T, MA H Z. Fault diagnosis for winding looseness of transformer based on VMD and WOA-

- SVM [J]. *Electric Machines & Control Application*, 2023, 50(8): 84-90.
- [18] 吕学宾, 田鹏, 孙忠凯, 等. 基于改进 VMD 和 AdaBoost-SVM 的隔离开关振动信号提取与故障诊断研究[J]. *山东电力技术*, 2023, 50(7): 44-52.
- LYU X B, TIAN P, SUN Z K, et al. Research on mechanical vibration signal extraction and fault diagnosis of disconnect switches based on improved VMD and AdaBoost-SVM [J]. *Shandong Electric Power*, 2023, 50(7): 44-52.
- [19] 陈士刚. 基于多路振动信号融合的高压隔离开关故障诊断方法研究[D]. 北京: 北京交通大学, 2019.
- CHEN S G. Research on fault diagnosis method of high voltage isolating switch based on multi-channel vibration signal fusion [D]. Beijing: Beijing Jiaotong University, 2019.
- [20] 刘柏泽. 基于多粒度自注意力机制下复合信号的隔离开关故障诊断[D]. 西安: 西安理工大学, 2024.
- LIU B Z. Isolating switch for composite signals based on multi-granularity self-attention mechanism troubleshooting [D]. Xi'an: Xi'an University of Technology, 2024.
- [21] 张开普. 基于振动和力矩信号融合的高压隔离开关故障诊断方法[D]. 成都: 西南交通大学, 2022.
- ZHANG K P. Research on fault diagnosis of high voltage disconnecter based on the fusion of vibration signal and torque signal [D]. Chengdu: Southwest Jiaotong University, 2022.
- [22] 周孟然, 宋乾坤. 基于 GAF 和卷积神经网络的轴承故障诊断研究[J]. *安徽理工大学学报(自然科学版)*, 2023, 43(1): 8-14.
- ZHOU M R, SONG Q K. Research on fault diagnosis of bearings based on GAF and convolution neural network [J]. *Journal of Anhui University of Science and Technology (Natural Science)*, 2023, 43(1): 8-14.
- [23] 肖雨松, 马宏忠. 基于格拉姆角场和深度残差网络的变压器绕组松动故障诊断模型[J]. *电机与控制应用*, 2024, 51(1): 29-38.
- XIAO Y S, MA H Z. Transformer winding looseness fault diagnosis model based on GAF and depth residual network [J]. *Electric Machines & Control Application*, 2024, 51(1): 29-38.
- [24] 薛健侗, 马宏忠, 杨洪苏, 等. 基于格拉姆角场与迁移学习-AlexNet 的变压器绕组松动故障诊断方法[J]. *电力系统保护与控制*, 2023, 51(24): 154-163.
- XUE J T, MA H Z, YANG H S, et al. A fault diagnosis method for transformer winding looseness based on Gramian angular field and transfer learning-AlexNet [J]. *Power System Protection and Control*, 2023, 51(24): 154-163.
- [25] 李宗源, 陈谦, 钱倍奇, 等. 基于格拉姆角场与并行 CNN 的并网逆变器开关管健康诊断[J]. *电力自动化设备*, 2024, 44(8): 153-159.
- LI Z Y, CHEN Q, QIAN B Q, et al. Health diagnosis of switch tube in grid-connected inverter based on Gramian angular field and parallel CNN [J]. *Electric Power Automation Equipment*, 2024, 44(8): 153-159.
- [26] 盛世龙, 王淑青, 王云鹤, 等. 基于格拉姆角场和 PCNN-BiGRU 模型的故障诊断方法及其应用[J]. *中国农村水利水电*, 2025, (2): 121-128.
- SHENG S L, WANG S Q, WANG Y H, et al. Fault diagnosis method and its application based on Gramian angular field and PCNN-Bigrum model [J]. *China Rural Water and Hydropower*, 2025, (2): 121-128.
- [27] WANG Z G, OATES T. Imaging time-series to improve classification and imputation[C]//*Proceedings 24th International Joint Conference on Artificial Intelligence*, Buenos Aires, 2015.
- [28] 朱江, 汪帆, 曹春堂, 等. 基于 KLPP-K-means-BiLSTM 的台区短期电力负荷预测[J]. *电机与控制应用*, 2024, 51(3): 108-115.
- ZHU J, WANG F, CAO C T, et al. KLPP-K-means-BiLSTM based short-term power load forecasting for station areas [J]. *Electric Machines & Control Application*, 2024, 51(3): 108-115.
- [29] 李青, 张新燕, 马天娇, 等. 基于 SSA-CNN-BiGRU-Attention 的超短期风电功率预测模型[J]. *电机与控制应用*, 2023, 50(5): 61-71.
- LI Q, ZHANG X Y, MA T J, et al. Ultra-short term forecasting model of wind power based on SSA-CNN-BiGRU-Attention [J]. *Electric Machines & Control Application*, 2023, 50(5): 61-71.
- [30] 崔佳嘉, 马宏忠. 基于 CEEMDAN-小波阈值和 3D-CNN 的变压器铁心松动故障诊断模型[J]. *电机与控制应用*, 2022, 49(10): 46-52.

- CUI J J, MA H Z. Transformer iron core looseness fault diagnosis model based on CEEMDAN-wavelet-threshold and 3D-CNN [J]. *Electric Machines & Control Application*, 2022, 49(10): 46-52.
- [31] 司成志, 惠世贤, 邢超, 等. 基于变分模态分解和 CNN-BiGRU-Attention 神经网络的电机故障分类方法[J]. *高压电器*, 2025, 61(5): 189-196.
- SI C Z, HUI S X, XING C, et al. Fault classification method of motor based on variational modal decomposition and CNN-BiGRU-Attention neural network [J]. *High Voltage Apparatus*, 2025, 61(5): 189-196.
- [32] 卢恩豪, 冀大雄, 王霞. 基于卷积神经网络和注意力机制的自主水下机器人故障诊断研究[J]. *海洋信息技术与应用*, 2025, 40(2): 65-73.
- LU E H, JI D X, WANG X. The research on fault diagnosis of autonomous underwater vehicle based on convolutional neural networks and attention mechanisms [J]. *Journal of Marine Information Technology and Application*, 2025, 40(2): 65-73.
- [33] 施永, 黄宁, 谢缔, 等. 基于自注意力机制和 CNN 融合的燃料电池故障诊断技术[J]. *太阳能学报*, 2025, 46(5): 53-61.
- SHI Y, HUANG N, XIE D, et al. Fuel cell fault diagnosis technique based on self-attention mechanism and CNN fusion [J]. *Acta Energetica Solaris Sinica*, 2025, 46(5): 53-61.

收稿日期:2025-03-04

收到修改稿日期:2025-03-31

作者简介:

申张亮(1985-),男,博士,高级工程师,研究方向为变电检修及配网调度,18851601877@163.com;

* 通信作者:董媛(2001-),女,硕士研究生,研究方向为电力设备故障分析与诊断,dongyuan20011103@163.com。