

DOI: 10.19783/j.cnki.pspc.240363

声信号下基于双通道特征融合网络的电抗器故障诊断方法

孙抗¹, 张浩¹, 杨林², 常亮², 杨明¹

(1. 河南理工大学电气工程与自动化学院, 河南 焦作 454003; 2. 焦作市光源电力集团有限公司, 河南 焦作 454150)

摘要: 目前, 干式电抗器故障诊断方法主要围绕在基于振动信号的机械故障展开, 故障类型单一, 并且存在传感器安装困难等问题。为此, 搭建了基于声信号下的干式电抗器故障试验平台, 设置了多种故障类型。为了提升小样本下故障识别的准确率, 提出一种基于双通道特征融合网络的干式电抗器故障诊断方法。首先, 采用格拉姆角场(Gramian angle field, GAF)进行编码, 将一维时序转化为二维图像。其次, 采用双通道并行的CNN-ResNet网络结构, 引入高效通道注意力机制(efficient channel attention, ECA)来获取二维关键信息, 将二维图像特征与一维时序特征进行深度提取与融合。最后, 基于有限元仿真来获取源域数据, 采用迁移学习方法来获取目标域最优网络参数。试验对比表明: 所提方法相比其他方法有着较强的特征提取能力, 能够将故障特征显著分离, 在小样本下的故障识别准确率最高可达99.5%, 同时具有良好的泛化性和收敛速度。

关键词: 电抗器; 声信号; 故障; 特征

Fault diagnosis method of reactor based on a dual-channel feature fusion network with an acoustic signal

SUN Kang¹, ZHANG Hao¹, YANG Lin², CHANG Liang², YANG Ming¹

(1. School of Electrical and Automation, Henan Polytechnic University, Jiaozuo 454003, China;

2. Jiaozuo Guangyuan Electric Power Group Co., Ltd., Jiaozuo 454150, China)

Abstract: At present, the fault diagnosis methods of a dry reactor mainly focus on mechanical faults based on vibration signals. The fault type is singular, and there are problems such as difficulties with sensor installation. Thus, a dry reactor fault test platform based on an acoustic signal is built, and a variety of fault types are set up. To improve the accuracy of fault identification in small samples, a dry reactor fault diagnosis method based on a dual-channel feature fusion network is proposed. First, the one-dimensional time sequence is converted into two-dimensional image using Gramian angle field (GAF) encoding. Secondly, a two-channel parallel CNN-ResNet network structure is adopted, and an efficient channel attention (ECA) mechanism is introduced to obtain two-dimensional key information. Then the two-dimensional image features and one-dimensional time series features are extracted and fused. Finally, the source domain data is obtained based on finite element simulation, and the optimal network parameters of the target domain are obtained by the transfer learning method. Experimental comparison shows that the proposed method has stronger feature extraction ability than other methods, can significantly separate fault features, and the fault identification accuracy can reach 99.5% with small samples. It has good generalizability and convergence speed.

This work is supported by the National Natural Science Foundation of China (No. U1804143).

Key words: reactor; acoustic signal; fault; features

0 引言

电抗器作为变电站中的重要设备, 起到无功功率补偿和限制短路电流的作用, 在电力系统中得到

了广泛应用^[1]。受运行环境和长期振动影响, 干式电抗器在运行过程中容易发生绝缘缺陷故障和机械故障, 导致设备停运, 造成经济损失^[2]。因此, 在干式电抗器发生故障时能够快速准确地识别出故障类型, 对保证电网安全稳定运行具有重要意义。

国内外学者开展了一系列关于电抗器和变压器故障诊断方法的研究, 目前较为常见的是基于振动

基金项目: 国家自然科学基金项目资助(U1804143); 河南省科技攻关计划项目资助(202102210092)

信号的分析方法^[3-4]。振动信号由固定在油箱或者铁心表面的加速度传感器采集,具有科学性和合理性,但振动测点传感器安装复杂,易受环境干扰,容易出现测点选择困难和可靠性差的问题^[5]。另一方面,振动信号在反映如螺栓松动、铁心变形等机械故障时有着较高的灵敏度,但无法准确反映电气绝缘缺陷等问题^[6]。目前的研究多局限在机械松动程度的状态识别上^[7]。为了满足多种故障类型在线监测的需求,基于声信号下的故障诊断方法成为新的研究趋势。文献[8]基于变压器的声振特征,提出一种改进优化的变分模态分解算法,能够提取故障信号中的显著特征,但故障样本较少,该方法的泛化能力难以保证;文献[9]提出了一种基于F比的Mel频率倒谱系数特征优化算法,但难以保留故障全特征;文献[10]提出了一种改进的深度森林算法,提高了在小样本和复杂工况下模型的稳定性,但诊断精度仍有提升空间。

随着深度学习的发展,计算机视觉领域取得了突破性进展,研究者们提出了一系列网络架构,如CNN^[11]、AlexNet^[12]、ResNet、GoogleNet^[13]、VGGNet^[14]等。将一维振动信号转化为二维图像信息来激发计算机的“视觉能力”成为新的研究热点,文献[15]将时频域数据的灰度图输入到LeNet网络中进行故障诊断;文献[16]采用一种结合灰度图像数据增强和CNN的故障诊断方法。时频图和灰度图容易造成故障特征信息的缺失,精度存在一定不足,因此,文献[17]采用RP编码技术将轴承振动信号编码为二维图像,运用ResNet网络进行识别;文献[18]通过格拉姆角场和AlexNet实现变压器绕组松动的故障诊断。以上方法虽取得了良好的效果,但缺少不同方法和模型的对比验证。

本文搭建了声信号采集试验平台,设置了多种故障类型。然而真实可用的故障样本较为匮乏,为了充分发挥小样本下计算机的“视觉能力”,本文在深度特征融合的基础上,提出迁移学习方法来提升模型的诊断精度和收敛速度。最后将不同的编码方式和模型进行试验对比,验证了本文所提方法的优越性。

1 格拉姆角场原理

格拉姆角场(Gramian angular field, GAF)矩阵是一种用于时间序列数据分析的方法,它将时间序列转换为图像形式,以便于进行二维图像特征提取^[19]。具体实施步骤如下:设时间序列数据 $X = \{x_1, x_2, \dots, x_i\}$,首先对其进行归一化处理,将其归一化至 $[-1, 1]$

范围内,以 \tilde{x}_i 来表示,如式(1)所示。

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

然后将一维时间序列从直角坐标系转换到极坐标系,如式(2)所示。

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

式中: i 为时间节点; ϕ_i 为极坐标中的角度; N 为正则化极坐标系统张成空间的常数因子; \tilde{x}_i 与 ϕ_i 是一一映射关系,通过极坐标中的半径 r_i 能够保留时间序列数据的全信息。

将角度变化转化成多维矩阵还需引入格拉姆角差场(Gramian angular difference field, GADF)和格拉姆角和场(Gramian angular summation field, GASF),定义分别如式(3)和式(4)所示。

$$F_{\text{GADF}} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (3)$$

$$F_{\text{GASF}} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$

通过归一化处理、坐标系转换和三角矩阵转化3个步骤,将时间序列数据的差异映射为图像的颜色变化,使得数据的不同数值对应于图像中的不同颜色,通过选择适当的颜色映射方案,可以将计算机视觉技术应用于时间序列数据的研究,GAF图像编码示意图如图1所示。

用 X_i 、 X_j 分别表示时间序列中的第 i 和第 j 个数据点, $G_{i,j}$ 表示第 i 和第 j 个数据点之间的相似度,将两角和差公式展开,可得到式(5)。

$$G_{i,j} = \frac{1}{2} \cos\left(\frac{X_i - X_j}{\varepsilon}\right) + \frac{1}{2} \quad (5)$$

式中: ε 为标准差;缩放系数为 $1/2$ 。令 $\phi_i = X_i - X_j / \varepsilon$, $\phi_j = 0$,当时间序列之间差异较小时,余弦函数值接近1;当差异较大时,余弦函数值接近0。这个特性使得GASF适合于保留时间序列的整体特征,强调序列中的相对位置关系和整体趋势。结合实际情况,为了更好地反映故障特征,本文采用GASF编码方式进行数据处理。

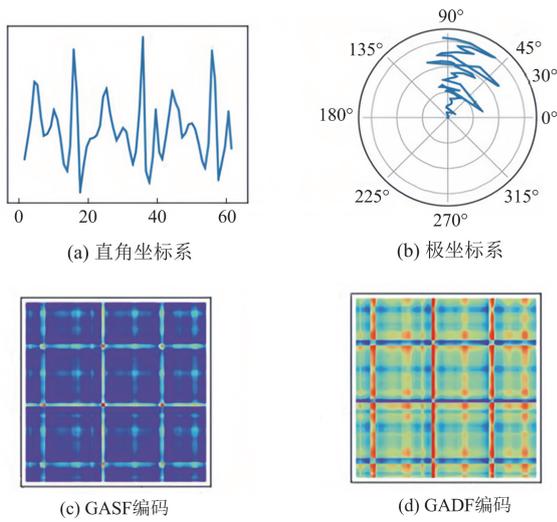


图 1 GAF 图像编码示意图

Fig. 1 Schematic of GAF image encoding

2 干式电抗器故障声信号采集与处理

2.1 试验平台搭建与故障设置

本试验采用的主要设备有：干式空心电抗器，额定电压为 10 kV；工频变压器，容量为 50 kVA，初级电压为 0.4 kV，次级电压为 100 kV；电容分压器，额定电压为 100 kV，分压比为 1000:1，电容值为 415.1 pF；限流电阻，阻值为 4 kΩ；大电流发生器：输入电压为 380 V，输出电压为 63.5 V，输入电流为 44 A，输出额定电流为 262.4 A，试验采用的滤波器为低通滤波器，工作频率为 0~20 kHz，高于 20 kHz 的高频噪声将被抑制，低于 100 Hz 的环境噪声将在数据处理过程中用程序直接滤除。实验室空开可以安全承载的最大电流为 100 A，满足实验要求。试验原理及平台搭建如图 2 所示。

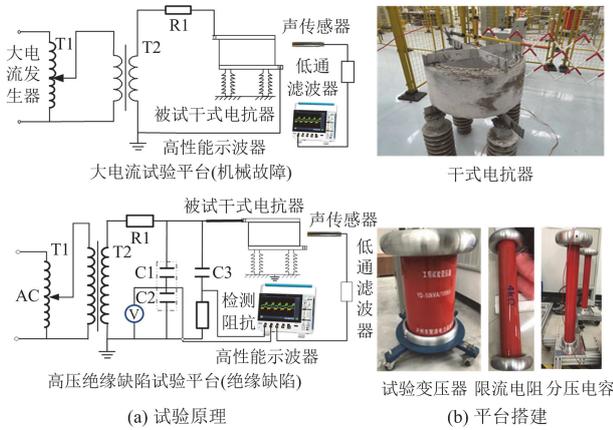


图 2 试验原理及平台搭建

Fig. 2 Test principle and platform construction

在 10 kV 干式电抗器上分别设置金属异物缺陷、污秽缺陷，分别如图 3(a)和图 3(b)所示。金属异物通过将多个长短不一的铜丝吸附在干式电抗器包封上来模拟，污秽为单位平方厘米中 36.4 mg 硅藻土与 5.2 mg NaCl 按照 7:1 比例混合，将之均匀涂覆^[20]。

干式电抗器在运行过程中受电磁力的影响导致螺栓松动，试验通过调节螺栓的预紧力来模拟螺栓松动故障，如图 3(c)所示^[21]。根据干式电抗器机械结构，试验通过同时松动多个支撑绝缘子在下星型架上的固定螺栓来模拟支撑绝缘子松动故障，如图 3(d)所示。

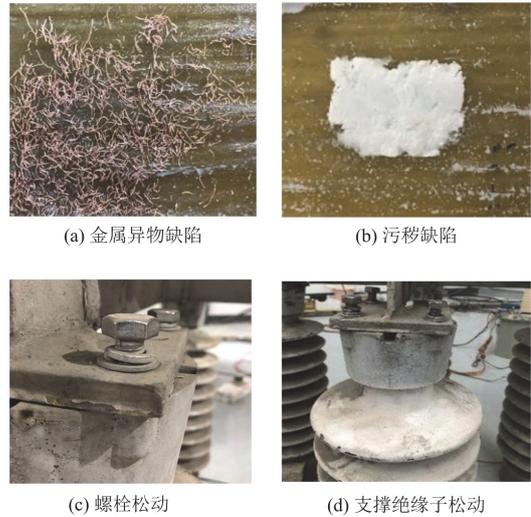


图 3 故障设置

Fig. 3 Fault setting

2.2 数据采集与 GAF 图像编码

声压传感器型号为 CZ-200，声压传感器按照《GBT 1094.10-2022 电力变压器 第 10 部分声级测定》要求布置在距离干式电抗器轮廓面 2 m、高度为 1 m 的位置^[22]。IEPE 调理器为 4 通道，输入为 24 V，输出为 4~20 mA。声信号采集设备为泰克高性能数字示波器(Tektronix*MS044，四通道，带宽为 1.5 GHz，采样率为 6.25 GS/s)。使用声压传感器和示波器进行数据采集，采样频率设置为 62.5 kHz。

本实验测点布置方案共有 12 个测点，一次采用 4 个声传感器，分 3 组对试验声信号数据进行采集，选择最佳测点将声信号数据截取为长度相等的时序数据，每类数据有 300 个采样点，每类故障构造 250 个时间序列故障样本。在 PyCharm 软件中运用 GASF 算法进行图像编码，金属异物缺陷、支撑绝缘子松动、螺栓松动、污秽缺陷 4 种故障分别对应标签 0—3，对每种故障状态下的时序数据进行批量图像转换，并按照 8:2 的比例划分训练集和测试

集, 具体的数据处理图片展示如图 4 所示。

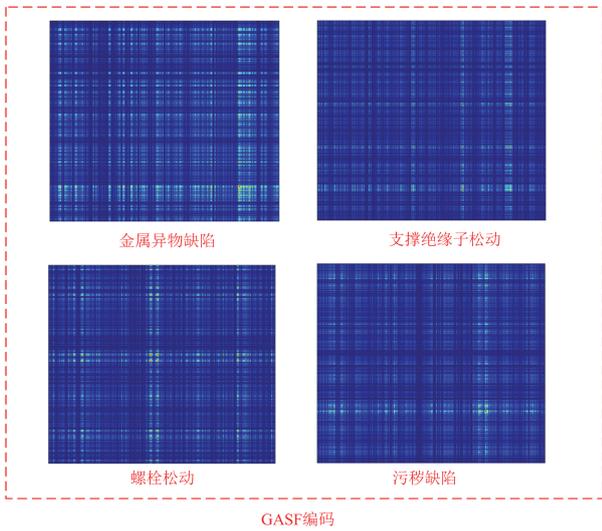
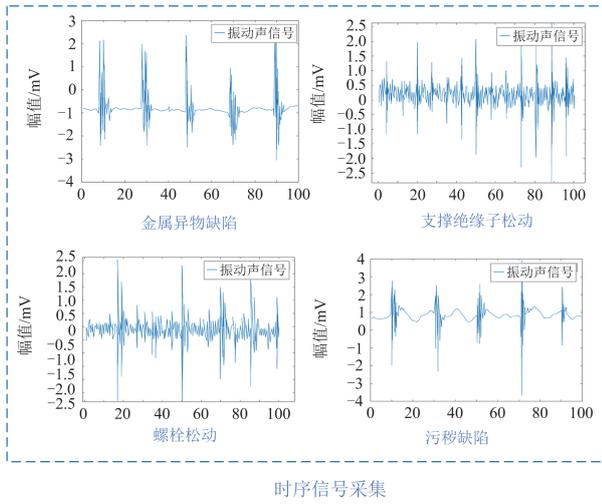


图 4 数据处理

Fig. 4 Data processing

3 双通道特征融合网络

3.1 改进的 CNN-ResNet 网络

CNN 是一种深度学习模型, 由输入层、卷积层、池化层、全连接层、输出层等构成, 结构示意图如图 5 所示。CNN 的层级结构和参数共享特性使其在图像识别、物体检测、图像分割等计算机视觉任务中表现出色。CNN 能够自动提取图像中的特征, 并通过反向传播算法进行端到端的训练, 使得模型能够

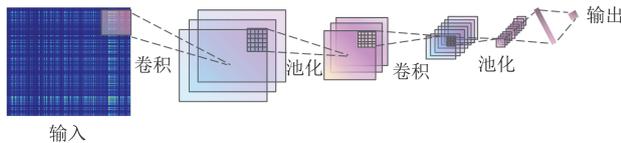


图 5 CNN 结构示意图

Fig. 5 Schematic diagram of CNN structure

逐渐优化, 学习到更有效的特征, 因此本文选择利用 CNN 来提取故障图像的特征。

由于故障声信号一维时序数据之间存在一定的隐藏依赖关系, 而 CNN 网络偏重于提取二维特征, 忽略了这种隐藏特征, 因此本文采用 ResNet 深度残差网络来提取一维隐藏特征。残差块中 x 为输入, 网络中堆叠层将输入映射为 $F(x)$, 输出为 $H(x)$ 。输入与输出之间的误差表示为式(6)^[23]。

$$F(x) = H(x) - x \quad (6)$$

若输入到输出为直连(shortcut)路径, 此时 x 已知, 等价于学习 x 到 $H(x)$ 的映射, 由残差结构可知 $F(x)$ 的表达式为

$$F(x) = \beta_2 \lambda(\beta_1 x) \quad (7)$$

式中: β_1 、 β_2 分别表示残差网络中第一、二层的权重; λ 为 ReLU 函数。可见 ResNet 网络很好地解决了随着网络层数增加, 梯度信号逐渐变小, 从而导致训练变得困难等问题。

高效通道注意力机制(efficient channel attention, ECA)的框架如图 6 所示, 其中: W 、 H 分别表示图像宽度和高度; χ 表示空间维度。为了充分挖掘特征融合当中通道的关键信息, 本文在 CNN 卷积层之后加入 ECA, 这种思想减少了计算量, 在一定程度上加快了计算速度, 同时保留了各通道之间的全局特征^[24]。直接在特征图上进行一维卷积, 卷积核的大小 k 可以自适应调整, 与输入的维数 C 的关系如式(8)所示。

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (8)$$

式中: $\lfloor \alpha \rfloor_{\text{odd}}$ 表示 α 的最近奇数; γ 和 b 表示用于控制卷积核大小与通道数比例的超参数, 通常分别取 2 和 1。卷积后的权重 ω 满足式(9)。

$$\omega = \sigma(C_{1Dk}(y)) \quad (9)$$

式中: σ 为 Sigmoid 激活函数; C_{1Dk} 为一维卷积数; y 为通道数。

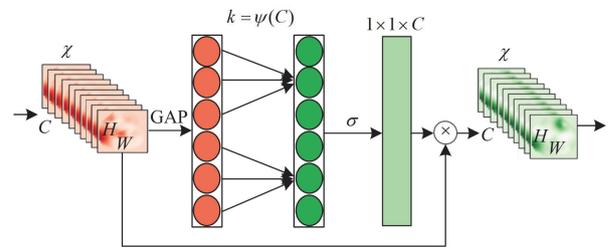


图 6 ECA 框架

Fig. 6 ECA framework

CNN 能够对二维图像特征进行有效提取, 结合 ResNet 对深度网络的优势, 构建双通道的网络结

构。CNN 的卷积层和 ECA 用于提取 GAF 图像的关键特征，池化层用于对特征图进行下采样，减少特征图尺寸和计算量，全连接层将 CNN 提取到的图像特征张量记为 T_1 ；ResNet 提取故障信号的时序特征，残差块可以帮助解决梯度消失问题，加速训练过程，利用 Dropout 层提高网络的泛化能力，防止过拟合，通过全连接层输出的时序特征张量记为 T_2 。最后特征融合模块将两个输出同维张量进行融合，得到新的特征张量为 T ，将 T 输入到最后的全连接层，进行特征变换得到最终的结果，网络结构如图 7 所示。

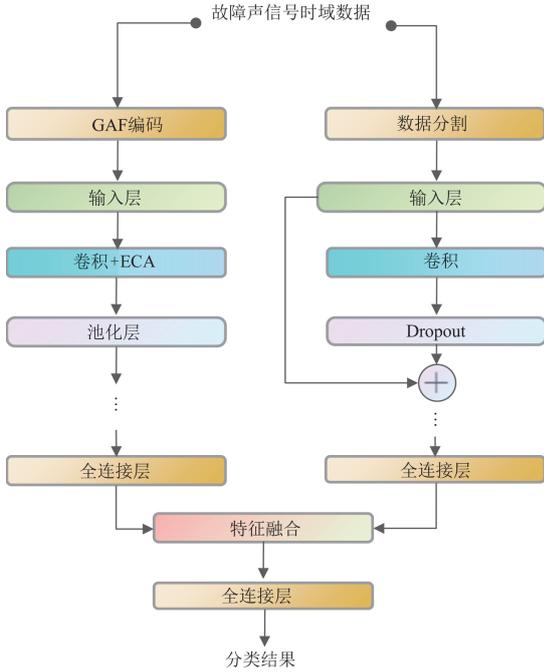


图 7 改进的 CNN-ResNet 网络结构

Fig. 7 Improved CNN-ResNet network architecture

3.2 网络迁移诊断流程

迁移学习是深度学习的一种策略，迁移学习将在大数据下预训练好的网络模型迁移到相似任务中进行参数微调，对工程而言，可以节省大量资源和时间^[25]。在故障样本较少的情况下，引入迁移学习能减少迭代次数，提高模型的泛化能力和稳定性。

采用有限元仿真的方法，建立干式空心电抗器多物理场耦合模型，来获取源域数据。电抗器声信号以振动速度为声源，以空气为传播介质，声信号在传播过程中遵循的运动方程、连续方程^[26]为

$$\begin{cases} \rho_0 \left(\frac{\partial v_x}{\partial t} + \frac{\partial v_y}{\partial t} + \frac{\partial v_z}{\partial t} \right) = - \left(\frac{\partial p}{\partial x} + \frac{\partial p}{\partial y} + \frac{\partial p}{\partial z} \right) \\ \frac{\partial p}{\partial t} = -\rho_0 \left(\frac{\partial v_x}{\partial t} + \frac{\partial v_y}{\partial t} + \frac{\partial v_z}{\partial t} \right) \end{cases} \quad (10)$$

式中： ρ_0 为流体密度； v_x 、 v_y 、 v_z 分别为电抗器在谐响应计算中的 x 、 y 、 z 轴的振动速度； t 为时间变量； p 为空间各点声压，满足状态方程 $p = c_0^2 \rho$ ，其中 c_0 为声速， ρ 为媒介密度增量。

在理想情况下电抗器的简谐运动声波满足波动方程式(11)。

$$\frac{\partial^2 p}{\partial x^2} + \frac{\partial^2 p}{\partial y^2} + \frac{\partial^2 p}{\partial z^2} - \frac{1}{c_0^2} \frac{\partial^2 p}{\partial t^2} = 0 \quad (11)$$

在 COMSOL 仿真软件当中进行声学分析，材料属性数值如表 1 所示，定义耦合声源和边界条件，求解电抗器周围的声压分布，得到仿真故障样本。

表 1 材料属性

Table 1 Material properties

材料	属性	数值
铝	密度/(kg/m ³)	2700
	杨氏模量/GPa	70
	泊松比	0.33
	声速/(m/s)	6320
空气	密度/(kg/m ³)	1.205
	声速/(m/s)	340
	动力粘度/(Pa·s)	17.8 × 10 ⁻⁶

本文将改进的 CNN-ResNet 深度学习网络与迁移学习相结合，提出一种深度迁移学习的干式电抗器故障诊断方法，迁移诊断流程如图 8 所示，具体的迁移步骤如下。

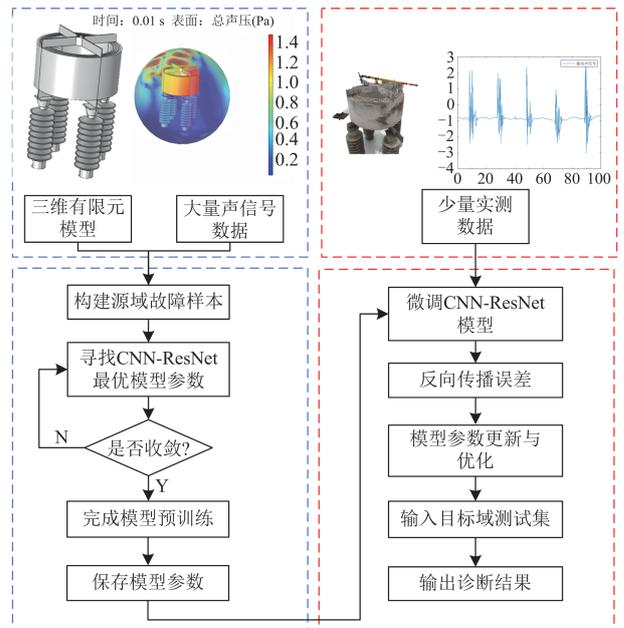


图 8 网络迁移诊断流程

Fig. 8 Network transfer diagnostic process

步骤 1: 采用仿真方法获得大量故障声信号数据作为源域数据, 划分训练集和测试集, 将训练样本输入到网络模型中, 并用测试集加以检验修正, 得到最优网络参数。

步骤 2: 将实测故障声信号数据作为目标域数据集, 将获取到的诊断性能优异的源深度模型参数迁移到目标域模型。

步骤 3: 冻结 CNN 层及 ResNet 网络层参数, 每层参数不随迭代训练发生改变, 利用少量训练样本微调网络模型, 训练期间采用反向传播误差进行模型更新与优化, 最后输入到目标域测试集来验证深度迁移网络性能。

通过仿真, 每种故障共得到 1000 组声信号样本, 按照编号顺序, 按比例将源域数据划分为训练集和测试集, 设置反向传播网络的最大迭代次数为 500 次, 学习率设置为 0.01, 目标误差为 1×10^{-6} , 如图 9 所示, 在经过 500 次迭代后得到的最优误差为 0.02, 保存最优模型参数并输入到目标域进行验证。

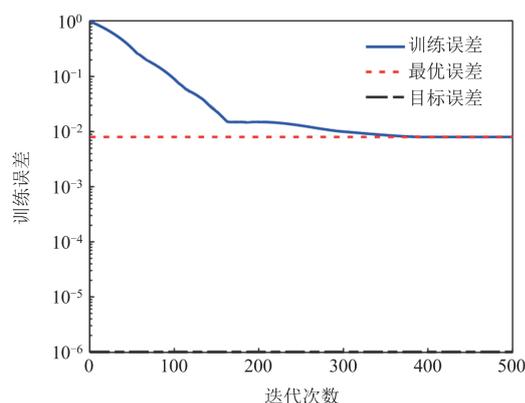


图 9 训练误差曲线

Fig. 9 Training error curve

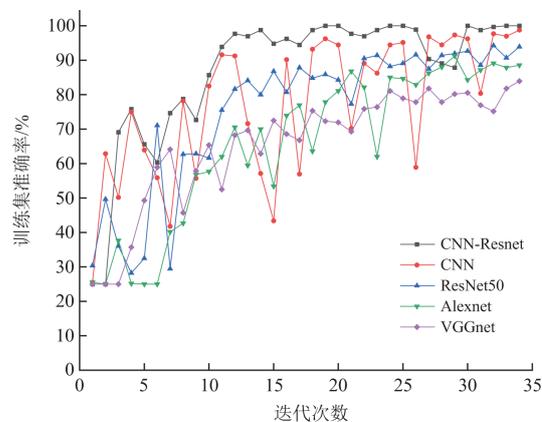
4 试验对比

4.1 不同网络模型的试验对比

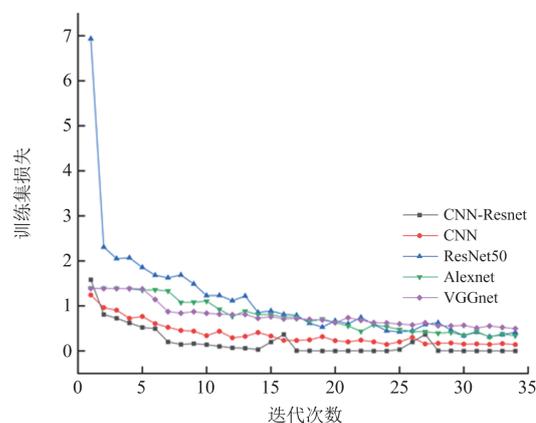
将 4 种不同类型故障下的 GAF 二维编码图像作为不同网络模型的输入, 进行消融对比试验。试验的运行环境均为 PyCharm, 深度学习框架均为 PyTorch, 在配置 Intel core i9-10900x 处理器和 NVIDIA RTX A5000 显卡的高性能计算机上运行不同网络模型。

本文采用的 5 种网络模型分别为改进的 CNN-ResNet、CNN、ResNet50、AlexNet 和 VGGNet, 经过 35 次迭代后, 得到训练集和测试集准确率和损失的变化曲线, 如图 10 所示。在训练集当中, CNN-ResNet 识别准确率要略高于其他网络, 虽然在迭代过程中出现了一定波动, 但训练过程中的整体网络

稳定性较其他网络明显提高, 训练集损失函数也以较快速度趋于收敛, 表明改进后的网络具有更快的训练速度。



(a) 准确率变化曲线



(b) 损失变化曲线

图 10 训练集准确率和损失变化曲线

Fig. 10 Training set accuracy and loss variation curves

CNN-ResNet 网络在测试集当中仅需几十次迭代, 准确率可达 98%, 如图 11(a)所示, 准确率要优于未经改进的 CNN 和 ResNet50, 说明本文提出的网络结构有着较高的特征提取能力。在测试集当中的损失函数曲线如图 11(b)所示, 经过几次迭代便可将损失降到接近于 0, 受硬件运行环境影响, 损失函数变化较其他网络呈小范围波动, 证明改进后的网络有着良好的鲁棒性。

4.2 不同编码方式的试验对比

时域信号灰度图像编码(time domain signal grayscale image encoding, TDS)将时间序列分析应用于图像领域, 相对其他彩色编码图像, 能够减小内存占用量, 提高计算速度。首先对原始数据进行归一化处理, 将处理后的一维数据映射到灰度图像的像素值 0~255 范围内, 使其转换成为灰度图像的

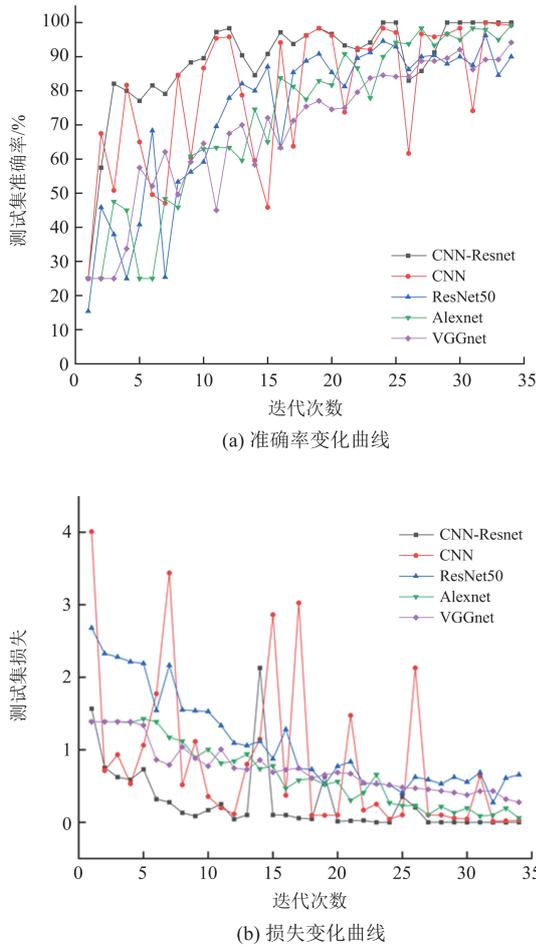


图 11 测试集准确率和损失变化曲线

Fig. 11 Test set accuracy and loss variation curves

灰度值，并按照编码方式进行排列^[27]。假设样本点数为 P ，灰度图尺寸为 $W \times H$ ，其中 $P = W \times H$ ，每个像素点灰度则为 $255 \times (c_i - c_{\min}) / (c_{\max} - c_{\min})$ ，其中 c_i 为不同点的像素取值。根据此方法，灰度图像的输出尺寸为 10×10 ，每种故障状态生成 250 张图像，同样按照 8:2 的比例划分训练集和测试集。

为验证 GAF 编码的优越性，本文将 GASF 和 TDS 两种编码方式进行对比试验，网络模型采用 CNN-ResNet、CNN 和 ResNet50，硬件配置和软件环境与上文相同，共进行 5 次分类试验，在训练集和测试集上分别求取 5 次试验的平均准确率，如表 2 所示。

为了直观地展示分类效果，使用测试集的混淆矩阵和 t-SNE 降维图来比较不同方法和模型的性能。由图 12 可知，3 种网络模型在 GAF 编码方式下的识别准确率均比采用灰度特征编码要高，采用改进的 CNN-ResNet 模型在测试集的识别准确率最高，可达 99.50%，高于其他网络模型。由表 2 可

知，该模型有着较强的泛化能力，没有出现拟合。由图 13 可知，本文所提方法能够将 4 种不同故障特征显著分离，和其他网络模型和方法相比，有着较优的特征分类能力。

表 2 不同编码方式平均准确率

Table 2 Average accuracy of different coding methods

采用方法	平均准确率/%	
	训练集	测试集
GASF+CNN-ResNet	99.80	99.10
GASF+CNN	98.20	96.75
GASF+ResNet50	99.30	95.00
TDS+CNN-ResNet	89.10	85.50
TDS+CNN	82.20	78.10
TDS+ResNet50	78.50	75.00

4.3 不同方法的试验对比

为了更好地突出改进后的网络模型在声信号特征提取方面的有效性，将其与 1D-CNN、CNN-LSTM、CNN-ViT 进行完整性能对比，评价指标包括准确率、召回率和 F1 分数。为了保证实验结果的公正性，所有模型均在相同的硬件配置下进行训练和测试，且使用相同的原始样本总量，共进行 5 次分类试验，求取平均数，如表 3 所示^[28]。

表 3 不同方法平均评价指标

Table 3 Average evaluation metrics of different methods

采用方法	准确率/%	召回率/%	F1 分数/%
CNN-ResNet	99.50	99.37	99.28
1D-CNN	91.72	90.46	90.24
CNN-LSTM	95.77	94.81	94.29
CNN-ViT	97.14	96.83	96.76

通过试验对比发现 1D-CNN 的总体表现较差，原因在于：由图 4 时序数据可知，当发生螺栓松动和支撑绝缘子断裂时，两种故障类型同为机械故障且时序特征极为相似，导致 1D-CNN 难以做到有效区分，整体性能较差。CNN-LSTM 和 CNN-ViT 性能较好，但不及本文 CNN-ResNet，说明本文所提方法在识别相似故障声信号时较为敏感，对不同故障类型的识别更加准确。

5 结论

1) 采用 GAF 将一维时序数据图像化，能够使卷积神经网络充分提取声信号之间的关联信息，在保留故障特征方面比时序灰度特征编码更具优势。

2) 改进的 CNN-ResNet 采用双通道输入，嵌入 ECA 有助于提取全局关键特征，与传统 CNN 相比，测试集故障识别准确率提升了 2.35%。

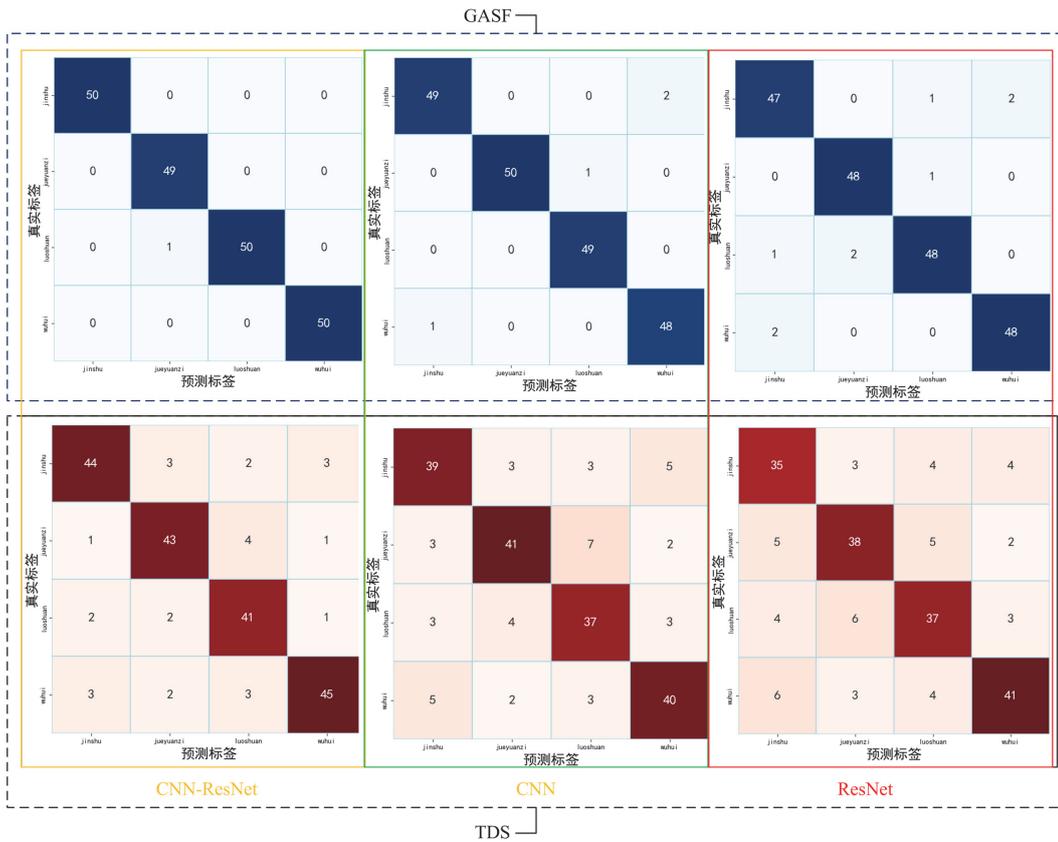


图 12 不同方法测试集混淆矩阵对比

Fig. 12 Comparison of confusion matrices for different methods test sets

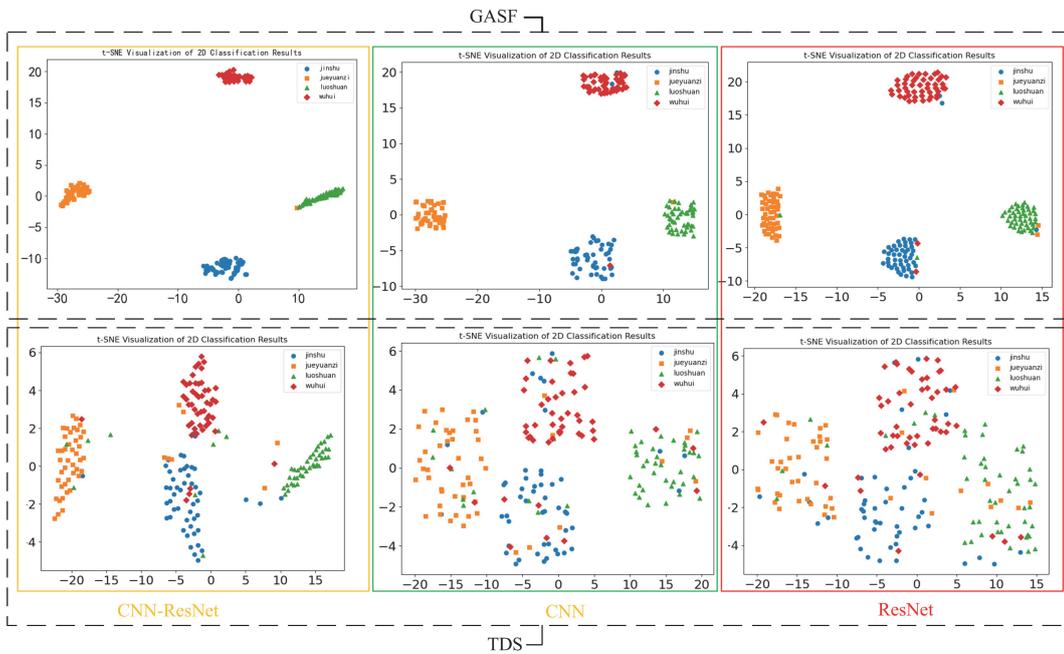


图 13 不同方法测试集 t-SNE 降维图对比

Fig. 13 Comparison of t-SNE downscaling plots for different methods test sets

3) 采用迁移学习方法, 能够加快网络的收敛速度, 在小样本下模型泛化性得以满足, 可为工程应用提供参考。

4) 本文所提方法和其他声信号提取方法相比有着较高的识别精度, 该方法也可应用于其他电气装备的故障诊断当中。

5) 目前的研究还仅涉及基于声信号的故障类型识别, 还未能实现基于传感器阵列的多故障实时定位, 下一步可对其进行重点研究。

参考文献

- [1] 咸日常, 鲁尧, 陈蕾, 等. 干式空心串联电抗器匝间短路故障特征研究[J]. 电力系统保护与控制, 2021, 49(18): 10-16.
XIAN Richang, LU Yao, CHEN Lei, et al. Fault characteristics of an inter-turn short circuit of a dry-type air core series reactor[J]. Power System Protection and Control, 2021, 49(18): 10-16.
- [2] 魏旭, 吴书煜, 姜宁, 等. 高压电抗器振动特性及实验分析[J]. 高压电器, 2019, 55(11): 66-73.
WEI Xu, WU Shuyu, JIANG Ning, et al. Theoretical and experimental analyses on high-voltage reactor vibration characteristics[J]. High Voltage Apparatus, 2019, 55(11): 66-73.
- [3] 周兵, 王延召, 胡静竹, 等. 并联电抗器振动特性及声功率级计算[J]. 高电压技术, 2019, 45(11): 3685-3692.
ZHOU Bing, WANG Yanzhao, HU Jingzhu, et al. Vibration characteristics and acoustic power level calculation of shunt reactors[J]. High Voltage Engineering, 2019, 45(11): 3685-3692.
- [4] 刘建锋, 李志远, 周亚茹. 基于漏磁场和 ICOA-ResNet 的变压器绕组早期故障诊断[J]. 电力系统保护与控制, 2024, 52(9): 99-110.
LIU Jianfeng, LI Zhiyuan, ZHOU Yaru. Transformer windings based on leakage field and ICOA-ResNet early fault diagnosis[J]. Power System Protection and Control, 2024, 52(9): 99-110.
- [5] 高树国, 张明文, 吴书煜, 等. 基于振动感知的油浸式电抗器松动故障检测方法[J]. 振动与冲击, 2022, 41(11): 42-49.
GAO Shuguo, ZHANG Mingwen, WU Shuyu, et al. Loose fault detection method of oil immersed reactor based on vibration perception[J]. Journal of Vibration and Shock, 2022, 41(11): 42-49.
- [6] 余长厅, 黎大健, 陈梁远, 等. 基于声纹及振动的变压器故障诊断技术研究[J]. 高压电器, 2019, 55(11): 248-254.
YU Changting, LI Dajian, CHEN Liangyuan, et al. Transformer fault diagnosis technique based on voiceprint and vibration[J]. High Voltage Apparatus, 2019, 55(11): 248-254.
- [7] 张朝龙, 何怡刚, 杜博伦, 等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(1): 81-89.
ZHANG Chaolong, HE Yigang, DU Bolun, et al. Intelligent fault diagnosis method for power transformer based on deep learning[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 81-89.
- [8] 马宏忠, 王健, 杨启帆, 等. 基于声振特征区分的 SMA 优化 SVM 变压器机械松动识别方法[J]. 电机与控制学报, 2023, 27(10): 42-53.
MA Hongzhong, WANG Jian, YANG Qifan, et al. SMA-optimized SVM transformer state identification method based on acoustic vibration feature differentiation[J]. Electric Machines and Control, 2023, 27(10): 42-53.
- [9] 王荣昊, 李喆, 孙正, 等. 基于 FISVDD 与 GRU 的变压器声纹识别技术[J]. 高电压技术, 2022, 48(11): 4546-4556.
WANG Ronghao, LI Zhe, SUN Zheng, et al. Transformer voiceprint recognition technology based on FISVDD and GRU[J]. High Voltage Engineering, 2022, 48(11): 4546-4556.
- [10] 李东东, 蒋海涛, 赵耀, 等. 极端条件下基于改进深度森林的行星齿轮箱故障诊断方法[J]. 电力系统保护与控制, 2023, 51(11): 39-50.
LI Dongdong, JIANG Haitao, ZHAO Yao, et al. Fault diagnosis technology of a planetary gearbox based on an improved deep forest algorithm under extreme conditions[J]. Power System Protection and Control, 2023, 51(11): 39-50.
- [11] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image net classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, USA: 1-9.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C] // International Conference on Learning Representations (ICLR), May 7-9, 2015, San Diego, USA: 1-14.
- [15] 吴晨芳, 杨世锡, 黄海舟, 等. 一种基于改进的 LeNet-5 模型滚动轴承故障诊断方法研究[J]. 振动与冲击, 2021, 40(12): 55-61.
WU Chenfang, YANG Shixi, HUANG Haizhou, et al. An

- improved fault diagnosis method of rolling bearings based on LeNet-5[J]. *Journal of Vibration and Shock*, 2021, 40(12): 55-61.
- [16] 肖雄, 肖宇雄, 张勇军, 等. 基于二维灰度图的数据增强方法在电机轴承故障诊断的应用研究[J]. *中国电机工程学报*, 2021, 41(2): 738-749.
XIAO Xiong, XIAO Yuxiong, ZHANG Yongjun, et al. Research on the application of the data augmentation method based on 2D gray pixel images in the fault diagnosis of motor bearing[J]. *Proceedings of the CSEE*, 2021, 41(2): 738-749.
- [17] 张龙, 胡燕青, 赵丽娟, 等. 采用递归图编码技术与残差网络的滚动轴承故障诊断[J]. *西安交通大学学报*, 2023, 57(2): 110-120.
ZHANG Long, HU Yanqing, ZHAO Lijuan, et al. Fault diagnosis of rolling bearings using recurrence plot coding technique and residual network[J]. *Journal of Xi'an Jiaotong University*, 2023, 57(2): 110-120.
- [18] 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 Jiantong, MA Hongzhong, YANG Hongsu, 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.
- [19] 古莹奎, 吴宽, 李成. 基于格拉姆角场和迁移深度残差神经网络的滚动轴承故障诊断[J]. *振动与冲击*, 2022, 41(21): 228-237.
GU Yingkui, WU Kuan, LI Cheng. Rolling bearing fault diagnosis based on Gram angle field and transfer deep residual neural network[J]. *Journal of Vibration and Shock*, 2022, 41(21): 228-237.
- [20] 全国变压器标准化技术委员会. 电力变压器 第 3 部分: 绝缘水平、绝缘试验和外绝缘空气间隙: GB/T 1094.3—2017[S]. 北京: 中国标准出版社, 2017.
Transformer Standardization Technical Committee of China. Power transformer part 3: insulation level, insulation test and outer insulation air gap: GB/T 1094.3—2017[S]. Beijing: Standards Press of China, 2017.
- [21] 高树国, 孟令明, 张玉焜, 等. 采用振动传感阵列的高压并联电抗器铁心松动故障诊断方法[J]. *振动工程学报*, 2023, 36(3): 875-884.
GAO Shuguo, MENG Lingming, ZHANG Yukun, et al. Fault diagnosis method for core loose of high voltage shunt reactor using vibration sensing array[J]. *Journal of Vibration Engineering*, 2023, 36(3): 875-884.
- [22] 全国变压器标准化技术委员会. 电力变压器 第 10 部分: 声级测定: GB/T 1094.10—2022[S]. 北京: 中国标准出版社, 2022.
Transformer Standardization Technical Committee of China. Power transformers part 10: determination of sound level: GB/T 1094.10—2022[S]. Beijing: Standards Press of China, 2022.
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016, Las Vegas, Nevada, USA: 770-778.
- [24] WANG Qilong, WU Banggu, ZHU Pengfei, et al. Efficient channel attention for deep convolutional neural networks[C] // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020, Seattle, USA: 11531-11539.
- [25] 邵海东, 肖一鸣, 颜深. 仿真数据驱动的改进无监督域适应轴承故障诊断[J]. *机械工程学报*, 2023, 59(3): 76-85.
SHAO Haidong, XIAO Yiming, YAN Shen. Simulation data-driven enhanced unsupervised domain adaptation for bearing fault diagnosis[J]. *Journal of Mechanical Engineering*, 2023, 59(3): 76-85.
- [26] 吴书煜, 马宏忠, 姜宁, 等. 基于多物理场耦合的特高压并联电抗器振动噪声仿真分析与实验研究[J]. *电力自动化设备*, 2020, 40(3): 122-127.
WU Shuyu, MA Hongzhong, JIANG Ning, et al. Simulation analysis and experimental research on vibration and noise of UHV shunt reactor based on multi physical field coupling[J]. *Electric Power Automation Equipment*, 2020, 40(3): 122-127.
- [27] 崔桂艳, 钟倩文, 郑树彬, 等. 基于 VMD 灰度图像编码和 CNN 的多传感融合轴承故障诊断[J]. *振动与冲击*, 2023, 42(21): 316-326.
CUI Guiyan, ZHONG Qianwen, ZHENG Shubin, et al. Multi-sensor fusion bearing fault diagnosis based on VMD gray level image coding and CNN[J]. *Journal of Vibration and Shock*, 2023, 42(21): 316-326.
- [28] 宁方立, 王珂, 郝明阳. 融合 CNN 和 ViT 的声信号轴承故障诊断方法[J]. *振动与冲击*, 2024, 43(3): 158-163, 170.
NING Fangli, WANG Ke, HAO Mingyang. Fault diagnosis method for bearing based on fusing CNN and ViT[J]. *Journal of Vibration and Shock*, 2024, 43(3): 158-163, 170.

收稿日期: 2024-03-20; 修回日期: 2024-05-21

作者简介:

孙抗(1982—), 男, 博士, 教授, 研究方向为电力装备智能故障诊断; E-mail: sunkang@hpu.edu.cn

张浩(1999—), 男, 通信作者, 硕士研究生, 研究方向为电力装备智能故障诊断。E-mail: 1422897774@qq.com

(编辑 周金梅)