

DOI: 10.13382/j.jemi.B2306960

基于多模态信息融合的变压器在线故障诊断方法*

邢致恺¹ 何怡刚¹ 姚其新²

(1. 武汉大学电气与自动化学院 武汉 430072; 2. 国网湖北省电力有限公司直流公司 宜昌 443000)

摘要:针对变压器的多模态数据中存在差异性和样本缺失的问题,提出了一种基于振动信号和红外图像数据的多模态信息融合方法,分析多模态数据对电力变压器故障状态进行有效、快速的评估。首先,该方法采用双向门控神经网络对振动信号的文本信息、振动信号的频域图和变压器的红外图像分别进行特征提取,并获得不同模态的重要特征向量。然后,使用交叉注意力机制建立不同模态之间的联系并进行特征向量融合。最后,通过卷积层和全链接层输出电力变压器的故障状态。实验数据采自于10 kV变压器,含振动信号和变压器的红外图像。实验结果表明,提出的多模态信息融合方法在4种评价指标上优于对比方法,其故障诊断准确率为96%。在不同的电压和电流等级下多模态信息融合方法能获得较为可靠的诊断结果且准确率高,可为变压器多模态数据的故障检测提供方法。

关键词:故障诊断;电力变压器;多模态信息融合;深度学习神经网络

中图分类号: TN919.5; TM407 **文献标识码:** A **国家标准学科分类代码:** 470.40

Transformer online fault diagnosis method based on multi-modal information fusion

Xing Zhikai¹ He Yigang¹ Yao Qixin²

(1. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China;

2. State Grid Hubei Direct Current Company, Yichang 443000, China)

Abstract: Addressing the challenges posed by variability and missing samples in multimodal data, we introduce a Multi-modal Information Fusion (MIF) technique that leverages both vibration and infrared image data. This innovative approach facilitates an effective and rapid assessment of power transformer fault states. First, a bidirectional gated recurrent unit (BGRU) is employed to extract features from the textual data of vibrations, the frequency images derived from vibrations, and the infrared images captured from the power transformer. The BGRU then yields feature vectors corresponding to different modalities. Subsequently, a cross-attention mechanism is utilized to establish relationships between these diverse modalities, enabling feature vector fusion. Finally, a combination of convolutional and fully connected layers determines the fault status of the power transformer. The experiment data come from the 10 kV power transformer, which contains the vibration signal and infrared images. Comparative analysis reveals that the MIF method outperforms benchmark techniques across four evaluation metrics, achieving a commendable fault diagnosis accuracy rate of 96%. Furthermore, the MIF methodology demonstrates its robustness by delivering highly reliable diagnostic outcomes under varying voltage and current conditions, offering a promising solution for the detection of faults in transformer multimodal data.

Keywords: fault diagnosis; power transformer; multi-modal information fusion; deep learning neural network

0 引言

电力变压器在输配电网络中起着至关重要的作用。

由于变压器成本昂贵,维修困难,研究故障诊断方法具有重要意义^[1]。因此,及时准确的发现变压器的故障状态对电力系统的稳定运行有着重要作用。

电力变压器的故障诊断方法可以分为离线检测和在线

线检测方法。离线方法以频率响应法、扫频阻抗法、对地电容测试等为主^[2]。在线检测方法主要有油中溶解气体分析^[3]、振动信号诊断^[4]等。上述方法中,振动信号诊断方法可以迅速的反映绕组机械状态、易于布置、不影响系统的运行等优点受到了广泛地关注^[5]。

目前,研究者在变压器振动信号故障诊断方法上取得了一定的研究成果。文献[6]研究交叉小波方法对变压器的振动信号幅频特征量进行提取,该方法诊断变压器绕组松动和铁芯磁路故障。文献[7]提取变压器振动信号的时域、频域、信息域上的特征量,利用投影算法和支持向量机对变压器进行故障诊断,对运行工况波动下实现高准确率故障诊断。文献[8]研究基于类格拉姆矩阵和卷积神经网络的变压器故障诊断方法,该模型工况平均识别准确率为 97.82%。文献[9]提出一种多重信息分解与时变权重组合的换流变压器振动状态参量综合预测方法,该方法对振动峰值与频谱复杂度变化趋势进行分析,反映了换流变压器的内部机械状态。文献[10]利用深度学习技术对变压器振动信号进行提取,通过混沌粒子群算法对分类模型的参数进行寻优,实现对变压器的故障诊断。

以上变压器故障诊断方法,基本都是在变压器实际运行时进行变压器铁芯松动、绕组松动等故障实验,采集其振动信号进行故障分析,只考虑了单一模态信息进行诊断。在实际运行中,变压器的采集数据是海量的,包含多种采集信号,不同模态的数据具有多源异构的特点,单一的振动信号不能较好的反映变压器的实时状态。传统的故障诊断方法对多模态数据的处理较差,无法对多源异构的数据进行数据融合并分析。随着机器学习的迅速发展,人工智能技术被广泛应用到变压器故障诊断,如群智能优化算法、特征选择、神经网络等。

目前,人工智能方法已经被广泛地应用到电力变压器的故障诊断^[11-12]。文献[13]提出一种基于残差前馈神经网络的变压器故障诊断方法,该方法处理小样本数据具有较好的性能。文献[14]提出了基于自适应差分进化算法与前馈神经网络(back propagation, BP)结合的故障诊断方法,该方法具有较好的诊断精度和更快的收敛速度。Jiang 等^[15]提出了一种基于隐马尔可夫模型的动量故障技术,该方法为实际运行和维护提供了决策依据。对上述算法进行分析,这些方法采用了不同的人工智能方法对进行变压器故障诊断,然而,它们只考虑故障数据的一种模态,而图像和频率等数据并未进行考虑。随着故障数据的模态的增加,单一的人工智能方法能力有所欠缺。因此,研究新的人工智能方法具有重要的现实意义。

近年来,深度学习在动作识别领域取得了很大的成功,其中多模态神经网络有效的解决了从多模态数据中

提取信息的问题^[16]。多模态数据主要包含文本、图像、信号等不同类型的形式。2019 年,文献[17]提出了一个多交互存储网络。2020 年,文献[18]在视觉问答中提出了多模态注意对抗学习。文献[19]提出了一种利用自我注意和选择性学习交叉参与特征的门控机制来捕捉长期背景的方法。文献[20]提出了一个多模态循环注意网络,通过学习时空注意力,能够较好地识别面部表情。上述方法利用不同的深度神经网络从多模态数据中提取特征,其核心是如何建立不同特征之间的连接,从而获得显著特征。

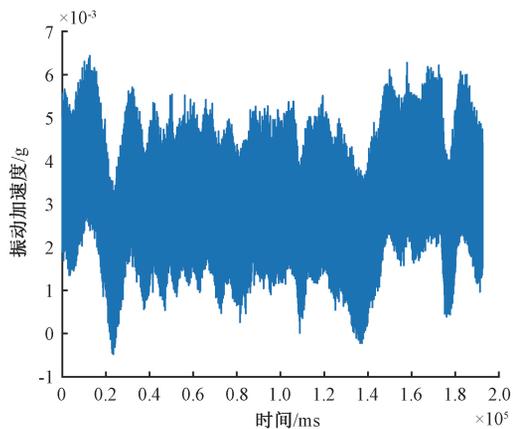
针对实际电力变压器多模态数据具有多源性、异构性和时序性的特点,提出了一种多模态信息融合的方法。该技术的核心概念是分析电力变压器的多模态信息并克服样本中不同模态异构性。同时考虑了电力变压器数据的时序问题,利用双向门控神经网络(bidirectional gated neural network, BGRU)对多模态数据进行特征提取。此外,在交叉注意机制从特征和相互之间获取重要信息,得到多模态数据的统一表征。最后,该方法对统一表征进行处理获得变压器的故障状态。

1 变压器故障诊断方法性能分析

变压器实际运行时受到热、电和机械应力的影响,存在不同的潜在故障类型。通过分析变压器的振动信号与其机械状态的关联,可以反映变压器内部的情况,通过变压器表面的振动信号对绕组和铁心进行诊断。一般认为变压器空载条件下的振动来自于铁心,而负载条件下的振动来自于绕组^[21]。而绕组的微小变形,其形变不明显,导致振动信号较为微弱,难以被算法发觉,为故障诊断带来困难。图 1 展示了绕组正常振动信号的时域和频域图,图 2 展示了绕组松动时振动信号的时域和频域图。从图中可以看出,发生故障时,时域信号变化较少,无法较好的区分变压器故障状态,而从频域图像中可以直观地看出两张图有着明显地差异,可以使算法能够更好地识别变压器故障。

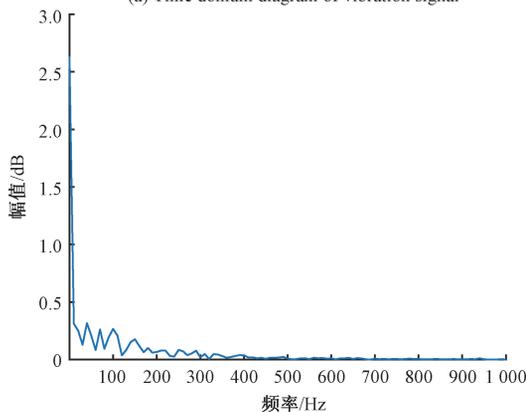
变压器红外图像可以直观地反映变压器表面的温度信息,红外图像故障诊断主要对变压器套管进行分析,检查套管的缺陷。而对变压器主题的分析主要是利用红外图像提供的温度对变压器的状态进行分析,而且当变压器内部故障不明显时,很难通过红外图像获得变压器内部情况。图 3 为电力变压器红外图像。从图中可以看出,红外图像中热点位置不一样,要针对不同的图像进行故障识别,需要识别算法具有泛化性。

针对振动信号对绕组微小变形故障诊断准确率低以及红外图像无法精确反映变压器内部状态的问题,将变压器的原始振动信号作为输入模型的文本信息,振动信



(a) 振动信号时域图

(a) Time domain diagram of vibration signal



(b) 振动信号频域图

(b) Time domain diagram of vibration signal

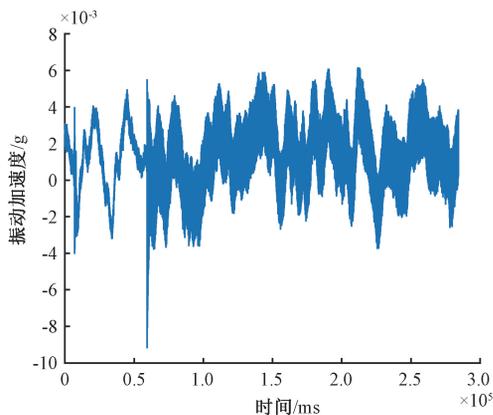
图 1 绕组正常振动信号的时域、频域图

Fig. 1 Time domain and frequency domain diagram of vibration signal with normal winding

号的频域图和变压器的红外图像作为输入模型的图像信息,研究多模态数据融合方法,对振动信号以及红外图像进行分析,利用不同模态之间的互补性、一致性获得变压器的统一表征,解决不同模态之间异构问题以及时序问题,最终获得变压器的故障状态。

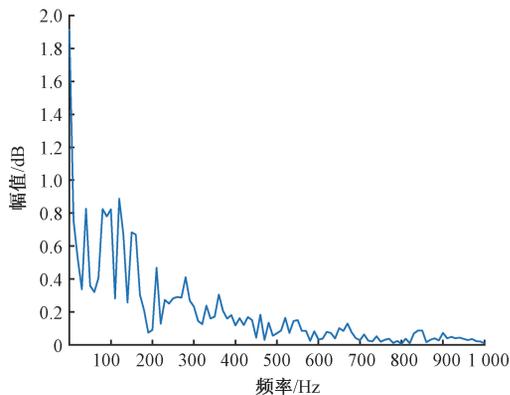
2 多模态信息融合模型

本节介绍提出的多模态信息融合模型,该模型的核心思想是对多模态数据提取有效信息,并学习不同模态之间的信息的关联性,从而获得多模态的统一表征,最后,通过统一表征得到变压器的故障状态,多模态信息融合模型的结构如图 4 所示。从图中可以看出,该模型的输入包含电力变压器的振动信号的文本形式、振动信号频域图和变压器的红外图像。由 BGRU 对基于时间序列的多模态数据进行特征提取,然后,利用交叉注意机制从提取特征中获得不同模态数据的注意力信息,最后,通过



(a) 振动信号时域图

(a) Time domain diagram of vibration signal



(b) 振动信号频域图

(b) Time domain diagram of vibration signal

图 2 绕组松动振动信号的时域、频域图

Fig. 2 Time domain and frequency domain diagram of vibration signal with loose winding

concat 融合层、卷积层和全链接层获得变压器故障类型。

2.1 多模态数据特征提取

多模态数据特征提取主要分为两部分,分别是文本特征提取和图像特征提取。文本数据和图像数据属于不同的模态,数据构成不同,为了提取重要特征,使用 BGRU 分别对两种模态进行学习。门控循环神经网络 (gate recurrent unit, GRU) 作为递归神经网络的一种变体,基于长短时记忆网络 (long short-term memory, LSTM) 的门控机制进行优化,用复位门和更新门代替 LSTM 中的输入门、输出门和遗忘门。该方法可以应对时间序列数据的长期依赖性,避免了“梯度消失”或“梯度爆炸”等问题^[22]。因此,采用 GRU 作为多模态数据时序特征提取的基本单元,将两个正向传播和反向传播的 GRU 网络叠加,同时进行双向特征提取。BGRU 可以综合考虑时序数据之间的联系,对文本和图像数据的特征提取有较强的能力,BGRU 模块的网络结构如图 5 所示,其中, x_1, x_2, \dots, x_t 为输入数据, y_1, y_2, \dots, y_t 为输出数据, h_1, h_2, \dots, h_n 为反向层的状态量, h'_1, h'_2, \dots, h'_n 为前向层的状态量。

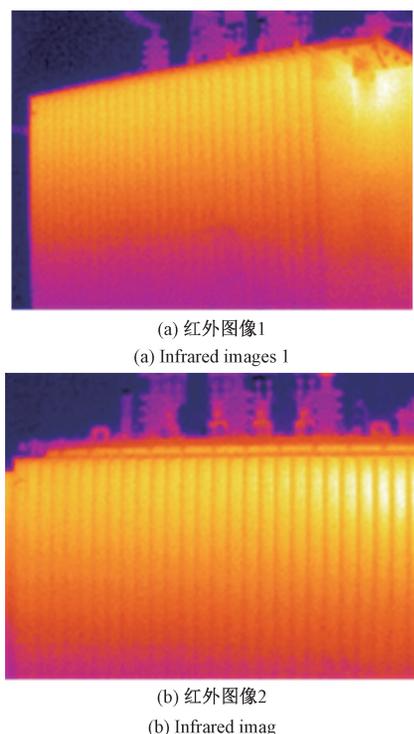


图 3 电力变压器红外图像

Fig. 3 The infrared images of the power transformer

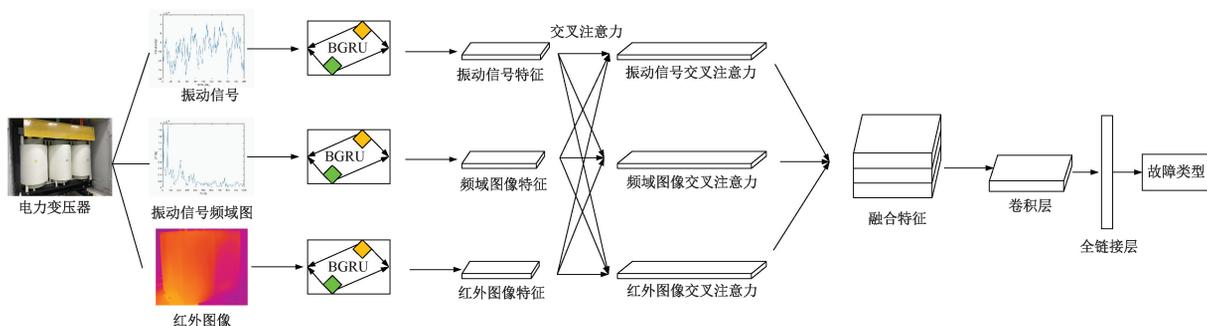


图 4 多模态信息融合模型的结构图

Fig. 4 The architecture of multi-modal fusion model

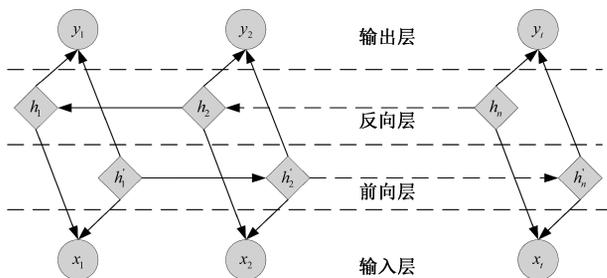


图 5 BGRU 结构图

Fig. 5 The architecture of BGRU

1) 正向计算公式为:

$$\begin{aligned} \vec{z}_t &= \sigma(\vec{W}_{xz}\vec{x}_t + \vec{W}_{hz}\vec{h}_{t-1} + \vec{b}_z) \\ \vec{r}_t &= \sigma(\vec{W}_{xr}\vec{x}_t + \vec{W}_{hr}\vec{h}_{t-1} + \vec{b}_r) \\ \vec{g}_t &= \tanh(\vec{W}_{xg}\vec{x}_t + \vec{W}_{hg}(\vec{r}_t \times \vec{h}_{t-1}) + \vec{b}_g) \\ \vec{h}_t &= (1 - \vec{z}_t) \times \vec{h}_{t-1} + \vec{z}_t \times \vec{g}_t \end{aligned} \quad (1)$$

2) 反向计算公式为:

$$\begin{aligned} \overleftarrow{z}_t &= \sigma(\overleftarrow{W}_{xz}\overleftarrow{x}_t + \overleftarrow{W}_{hz}\overleftarrow{h}_{t-1} + \overleftarrow{b}_z) \\ \overleftarrow{r}_t &= \sigma(\overleftarrow{W}_{xr}\overleftarrow{x}_t + \overleftarrow{W}_{hr}\overleftarrow{h}_{t-1} + \overleftarrow{b}_r) \\ \overleftarrow{g}_t &= \tanh(\overleftarrow{W}_{xg}\overleftarrow{x}_t + \overleftarrow{W}_{hg}(\overleftarrow{r}_t \times \overleftarrow{h}_{t-1}) + \overleftarrow{b}_g) \\ \overleftarrow{h}_t &= (1 - \overleftarrow{z}_t) \times \overleftarrow{h}_{t-1} + \overleftarrow{z}_t \times \overleftarrow{g}_t \end{aligned} \quad (2)$$

其中, r_t, z_t 是当前时间步下的更新门和重置门; g_t 是当前时刻的隐藏状态; h_{t-1} 和 h_t 分别是上一时刻和当前时刻的状态; W_{xz}, W_{xr} 和 W_{xg} 是连接到输入向量 x_t 的权重矩阵; W_{hz}, W_{hr} 和 W_{hg} 是连接到上一单元状态向量 h_{t-1} 的权重矩阵; b_z, b_r 和 b_g 是偏差向量; σ 是激活函数。最后, 将正向计算得出的 \vec{h}_t 和反向计算得出的 \overleftarrow{h}_t 结果叠

$$\vec{h}_t = \vec{h}_t + \overleftarrow{h}_t \quad (3)$$

振动信号原始数据存在波动, 细小的故障波动难以识别, 会降低故障诊断的准确率, 所以使用 BGRU 网络对振动信号的文本信息进行特征提取。由于该网络综合考虑了振动信号文本特征的时序问题, 有效的解决了数据在某一时刻存在的不确定性从而影响诊断结果的问题。将输出的振动信号文本特征矩阵记为:

$$P^T = \{p_1^T, p_2^T, \dots, p_L^T\} \quad (4)$$

在振动信号频域图像特征提取部分, 对振动信号的频域图像进行特征提取, 大多数算法仅分析 100 Hz 的振动而忽略其他有效的频率分量, 导致信息无法有效利用。

加起来作为模型的最终输出结果。

综合考虑所有频率分量,由 BGRU 提取高频分量中的特征,实现对故障的准确识别。将输出的频域特征矩阵记为:

$$\mathbf{Q}^T = \{q_1^T, q_2^T, \dots, q_L^T\} \quad (5)$$

在红外图像特征提取部分,存在电力变压器的红外图像中故障点的面积小,红外图像故障区域的识别比较复杂^[23]。为了克服这一问题,利用 BGRU 提取变压器红外图像的关键特征,可以更好的学习红外图像中的特征,从而识别图像中的故障点。将输出的红外图像特征矩阵记为:

$$\mathbf{O}^T = \{o_1^T, o_2^T, \dots, o_L^T\} \quad (6)$$

2.2 多模态信息融合

使用多交互注意机制来捕捉不同模态之间的双向交互。交叉注意力机制主要考虑两个模态之间的关系,考虑变压器数据中的振动信号的文本模态、频域模态和红外图像模态^[18]。变压器振动信号文本数据为文本模态 X_V ,频域图像为频域模态 X_F ,红外图像数据为图像模态 X_L 。首先,使用 3 个一维卷积核对两个模态进行编码,输出特征分别为 V, Q, K 。然后,利用交叉注意力机制分别计算不同模态之间的联系,得到 Y_V, Y_F 和 Y_L 。交叉注意力机制公式如式(7)所示。

$$Y_V = CM_{L \rightarrow V}(X_V, X_L) = \text{Softmax}\left(\frac{Q_V K_L^T}{\sqrt{d_k}}\right) V_L \quad (7)$$

其中, d_k 为方差。

在文本和图像特征提取中,采用了两种交叉注意力机制,重点提取信息部分和抑制不重要部分。将 $\mathbf{P}^T, \mathbf{Q}^T$ 和 \mathbf{O}^T 输入式(7)中,得到重要特征 $v_{vibration}^1, v_{frequency}^1$ 和 $v_{infrared}^1$ 。多模态交互机制不仅考虑了单模态数据,还考虑了跨模态数据。首先,获得原始特征向量 $v_{vibration}^1, v_{frequency}^1$ 和 $v_{infrared}^1$ 。然后,将计算 $v_{vibration}^1$ 与 $\mathbf{P}^T, \mathbf{Q}^T$ 和 \mathbf{O}^T 之间的注意力,以生成数据通道注意特征,从而获得跨模态注意特征 $v_{vibration}^{Att}$ 。其运算公式如式(8)~(11)所示。

$$v_{vib2vib}^{Att} = \text{Att}([\mathbf{P}^T, v_{vibration}^1]) \quad (8)$$

$$v_{vib2fre}^{Att} = \text{Att}([\mathbf{Q}^T, v_{vibration}^1]) \quad (9)$$

$$v_{vib2Inf}^{Att} = \text{Att}([\mathbf{O}^T, v_{vibration}^1]) \quad (10)$$

$$v_{vibration}^{Att} = \frac{v_{vib2vib}^{Att} + v_{vib2fre}^{Att} + v_{vib2Inf}^{Att}}{3} \quad (11)$$

其中, Att 是交叉注意力机制。

同时,对其他两个模态运用上述计算方法得到跨模态注意特征 $v_{frequency}^{Att}$ 和 $v_{infrared}^{Att}$ 。将 3 个跨模态注意特征通过融合层 concat 进行融合,获得多模态数据的融合特征。

$$V = \text{Concat}(v_{vibration}^{Att}, v_{frequency}^{Att}, v_{infrared}^{Att}) \quad (12)$$

2.3 故障诊断

将融合特征输入到一层卷积网络,并采用最大池化层来减小权重参数,最大池化层的 stride 设置为 2。将卷

积后得到的数据输入到全链接层,然后接 Softmax 回归输出最终不同故障的概率分布,从而得到变压器的故障状态。

$$\text{Fault} = \text{Softmax}(V) \quad (13)$$

由交叉熵损失函数来计算结果的损失,采用 Adam 优化算法迭代梯度,用于学习网络超参数。超参数设置如下: $\text{batch_size} = 64, \text{Max_epoch} = 150, \text{learning_rate} = 0.01$ 。为了防止欠拟合现象发生,加入了动态调整学习率的机制,在迭代次数为 400 和 800 时,将学习率分别调整为 0.001 和 0.000 1。

3 实验与结果

使用 Tensorflow 2.0 来运行多模态数据融合网络的代码。实验硬件主要包括 $\text{NVIDIA GeForce GTX 3060 GPU}$ 和 i7-11800H CPU 。每个比较算法运行在相同的实验平台上。为了获得比较算法的最佳性能,选择 10 折交叉验证方法对比较算法进行训练。

3.1 数据采集和实验设置

为采集变压器不同工况下的多模态数据,如图 6 所示搭建多模态数据采集平台,振动测量采用 pxi-4461 ,传感器采用 IEPE 压电式加速度传感器 CJ-YD500/N 安装在高压侧 B 相,分别松动绕组纵向拉杆与铁心横向拉杆,采集 10 kV 变压器在 $60\% I_N, 80\% I_N, 100\% I_N, 120\% I_N$ (I_N : 额定负载电流)下绕组正常与松动故障振动信号和 $60\% U_N, 80\% U_N, 100\% U_N, 120\% U_N$ (U_N : 额定空载电压)下铁心正常与松动故障下的振动信号。采样频率为 20 kHz。在不同的电流和电压等级下采集 10 000 组样本,训练集共包含 80 000 组数据,每组数据都包含振动信号的文本信息、频域图和红外图形。其中,利用额定电流和电压时的数据对提出的算法进行训练,将数据集随机分为 75% 和 25% 的训练和测试数据集,其他电流和电压等级的数据作为验证集。

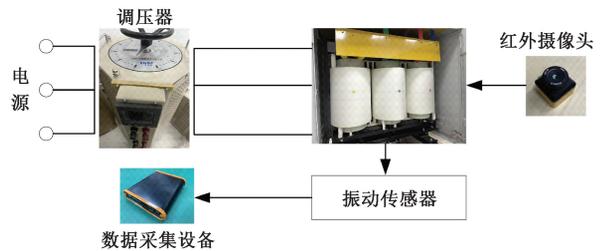


图 6 变压器多模态数据采集平台

Fig. 6 Transformer multimodal data acquisition platform

评价指标包括 $\text{Accuracy} (Ac), \text{Precision} (Pc), \text{F1 score} (F1), \text{Recall} (R)$ 。评价指标描述如式(14)~(17)所示。

$$Acc = \frac{TN + TP}{TN + TP + FN + FP} \quad (14)$$

$$Pc = \frac{TP}{FP + TP} \quad (15)$$

$$R = \frac{TP}{FN + TP} \quad (16)$$

$$F1 = 2 \times \frac{Pc \times R}{Pc + R} \quad (17)$$

其中, TN 为负类数, FN 为负类数, TP 为正类数, FP 为正类数。

3.2 多模态融合网络的训练过程

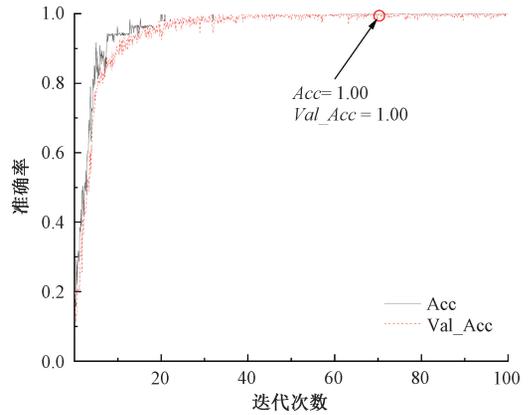
在本节中,对提出的多模态融合网络进行训练,分析模型的损失函数曲线。然后,通过接收者操作特征曲线(receiver operating characteristic curve, ROC)和它的曲线下面积(area under roc curve, AUC)对该方法的性能进行了分析。

图 7 展示了多模态信息融合方法(multi-modal information fusion, MIF)在训练和测试过程中的准确率曲线和误差率曲线。从图 7(a)中可知, MIF 的准确率曲线随着迭代次数的增加而增加,在前 30 次迭代时,训练曲线和测试曲线都存在震荡,说明 MIF 正更新算法中的权重,并学习有效值从而提升准确率。当迭代次数为 82 时, MIF 算法的训练集准确率达到 1.00,而且测试集的准确率也达到 1.00,说明算法在该数据集已学习到故障变化规律,能够准确的变压器故障进行诊断。从图 7(b)中可以看出,损失曲线在前期有剧烈的波动,但 MIF 的曲线仍有效的下降。当 MIF 的损失和验证损失曲线在 30 次迭代前曲线的下降速度很快,说明算法从多模态数据中正快速地学习特征,在 60 次迭代之后曲线逐渐趋于稳定,说明算法已经学习到较多的知识并进行微调。尤其是在 75 迭代次数时, MIF 的损失函数值为 0.003 1,验证损失函数值为 0.004 2。在之后的学习中,损失函数曲线有小幅度的震荡,仍在对多模态数据进行学习,在最后的 10 次迭代,损失和验证损失曲线趋于平稳,说明已经学习到多模态数据的统一表征,而且交叉注意力机制克服了多模态数据之间存在的复杂性,使算法更好的得到多模态数据的统一表征。

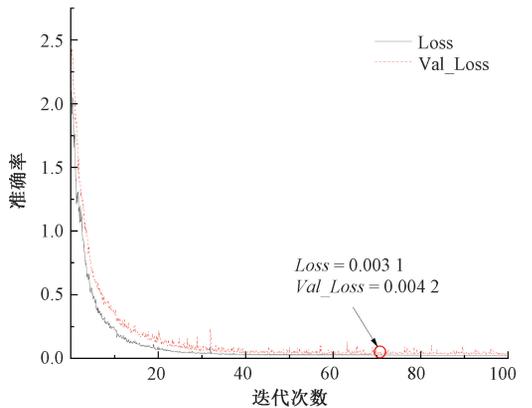
为了更直观的观察分类结果,使用 ROC 和 AUC 展示不同条件下 MIF 的分类结果, ROC 曲线和 AUC 结果如图 8 所示。从图中可以看出, MIF 算法在电压等级 60% U_N 和 80% U_N 时的故障诊断效果较好,分类的准确率高于 96%,在其他电流和电压等级下分类准确率均达到 95% 以上,说明 MIF 对不同的电路和电压等级下的故障识别较好,模型的泛化性较强。

3.3 与神经网络算法的对比实验

本节与 BGRU, 深度残差网络(deep residual



(a) 准确率曲线
(a) Accuracy curves



(b) 误差率曲线
(b) Error rate curves

图 7 训练过程的性能

Fig. 7 Performance of the training process

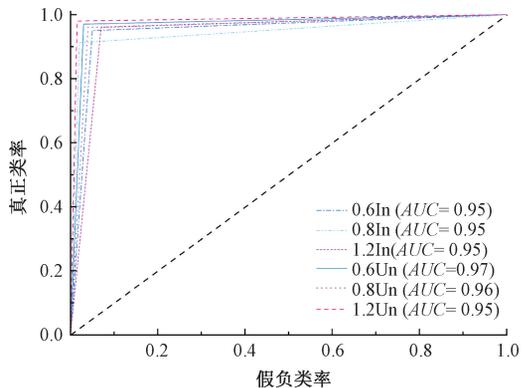


图 8 MIF 算法的 RUC 和 AUC 曲线

Fig. 8 The RUC and AUC of the MIF

shrinkage network, DRSN)^[24]和激励挤压网络(selective kernel network, SK-net)^[25]网络进行实验分析,通过对比评价指标对算法的性能进行分析。然后,利用混淆矩阵观察不同算法的分类结果。该节对比的网络均用额定电流和电压的数据对网络进行训练,由不同电流和电压等

级的数据进行验证。

表1展示了对比算法在不同的电流和电压等级下评价指标的均值结果。从表中可以看出DRSE算法在所有指标中比其他对比算法结果差,SK-net和BGRU的结果相差不大,MIF的结果表现最好。从以上分析可以看出,BGRU具有优秀的特征提取能力以及较高的分类效果,但是在处理多模态数据的时候,能力有所欠缺。通过在BGRU的基础上引入交互注意力机制,弥补了BGRU的不足,使网络可以更好的提取多模态数据的特征,从而获得不同模态的统一表征,使最终的分类精度有所提高。

表1 不同网络的结果

Table 1 The result of the compared networks

Network	A_c	P_c	R	$F1$
BGRU	0.941 8	0.938 5	0.937 7	0.938 1
DRSN	0.930 8	0.922 1	0.928 1	0.930 1
SK-net	0.942 1	0.937 5	0.940 8	0.937 8
MIF	0.960 7	0.961 7	0.964 1	0.962 9

4 结 论

本文提出了一种基于振动信号和红外图像数据的多模态信息融合技术,解决电力变压器的故障诊断问题。首先,MIF利用BGRU对振动信号的文本数据、振动信号的频域图和变压器的红外图像提取特征,获得不同模态的重要特征向量。然后,由交叉注意力机制对不同模态之间建立相互之间的联系,得到融合特征。最后,由卷积层和全链接层的求解得到变压器故障状态。该方法通过考虑多模态数据的时间相关性和不同模态之间的互补性,克服数据之间的差异性,得到统一表征。利用采集到的10 kV电力变压器多模态数据,通过实验验证可知,与其他对比方法而言,该算法具有较强的竞争能力,并且在60% I_N 、80% I_N 、100% I_N 、120% I_N 和60% U_N 、80% U_N 、100% U_N 、120% U_N 均可以得到准确的变压器故障状态,同时故障诊断准确率可以达到96%以上。总的来说,MIF对电力变压器多模态数据具有很好的应用前景,可以解决变压器的故障诊断问题。

对于电力变压器故障诊断而言,实际中有些故障案例难以获得,并且某些故障是首次出现,所以结合零样本学习的多模态信息融合电力变压器故障诊断方法有待研究。

参考文献

[1] 周亚中,何怡刚,邢致恺,等. 基于IDBO-ARIMA的电力变压器振动信号预测[J]. 电子测量与仪器学报, 2023,37(8):11-20.

ZHOU Y ZH, HE Y G, XING ZH K, et al. Vibration signal prediction of power transformer based on IDBO-ARIMA [J]. Journal of Electronic Measurement and Instrumentation, 2023,37(8):11-20.

- [2] 汲胜昌,张凡,师愉航,等. 基于振动信号的电力变压器机械状态诊断方法研究综述[J]. 高电压技术, 2020,46(1):257-272.
- JI SH CH, ZHANG F, SHI Y H, et al. Review on vibration-based mechanical condition monitoring in power transformers [J]. High Voltage Engineering, 2020,46(1):257-272.
- [3] 徐耀松,包力铭,管智峰,等. 基于IPPA优化PNN的变压器故障诊断研究[J]. 电子测量与仪器学报, 2022,36(10):138-145.
- XU Y S, BAO L M, GUAN ZH F, et al. Research on transformer fault diagnosis based on IPPA optimization of PNN [J]. Journal of Electronic Measurement and Instrumentation, 2022,36(10):138-145.
- [4] LEE S B, HABETLER T G. An online stator winding resistance estimation technique for temperature monitoring of line-connected induction machines [J]. IEEE Transactions on Industry Applications, 2003,39(3):685-694.
- [5] 林春耀,欧小波,杨贤,等. 冲击状态下的变压器振动特性及匝间短路故障检测[J]. 高电压技术, 2018,44(11):3569-3576.
- LIN CH Y, OU X B, YANG X, et al. Vibration characteristics and detection of inter-turn short-circuit fault under transformer suffering short-circuit impact[J]. High Voltage Engineering, 2018,44(11):3569-3576.
- [6] 赵莉华,丰遥,谢荣斌,等. 基于交叉小波的变压器振动信号幅频特征量提取方法[J]. 高电压技术, 2019,45(2):505-511.
- ZHAO L H, FENG Y, XIE R B, et al. Amplitude and frequency feature extraction for transformer vibration based on cross-wavelet transform [J]. High Voltage Engineering, 2019,45(2):505-511.
- [7] 赵莉华,张振东,张建功,等. 运行工况波动下基于振动信号的变压器故障诊断方法[J]. 高电压技术, 2020,46(11):3925-3933.
- ZHAO L H, ZHANG ZH D, ZHANG J G, et al. Diagnosis methods for transformer faults based on vibration signal under fluctuating operating conditions [J]. High Voltage Engineering, 2020,46:3925-3933.
- [8] 张占龙,肖睿,武雍焯,等. 换流变压器振动信号多层次特征提取模型研究[J]. 中国电机工程学报, 2021,41(20):7093-7104.

- ZHANG ZH L, XIAO R, WU Y Y, et al. Research on multi-level feature extraction model of converter transformer vibration signal [J]. Proceedings of the CSEE, 2021, 41(20): 7093-7104.
- [9] 吴书煜,汲胜昌,祝令瑜,等. 基于多重信息分解与时变权重组合的换流变压器振动状态参量综合预测方法[J]. 中国电机工程学报, 2020, 40(23): 7792-7804.
- WU SH Y, JI SH CH, ZHU L Y, et al. Comprehensive prediction method of converter transformer vibration state parameters based on multiple information decomposition and time-varying weight combination [J]. Proceedings of the CSEE, 2020, 40(23): 7792-7804.
- [10] 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 CH L, HE Y G, DU B L, et al. Intelligent fault diagnosis method of power transformer using deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 81-89.
- [11] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 87-97.
- WANG Y H, WANG ZH ZH, FU H, et al. Transformer fault diagnosis based on multi-strategy improved sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [12] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展 [J]. 仪器仪表学报, 2023, 44(8): 181-197.
- LI CH, WU Y F, YANG SH. Research progress of unevenly distributed data-driven fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 181-197.
- [13] 赵文清, 严海, 周震东, 等. 基于残差 BP 神经网络的变压器故障诊断 [J]. 电力自动化设备, 2020, 40(2): 143-148.
- ZHAO W Q, YAN H, ZHOU ZH D, et al. Fault diagnosis of transformer based on residual BP neural network [J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [14] 孔德钱, 张新燕, 童涛, 等. 基于差分进化算法与 BP 神经网络的变压器故障诊断 [J]. 电测与仪表, 2020, 57(5): 57-61.
- KONG D Q, ZHANG X Y, TONG T, et al. Transformer fault diagnosis based on differential evolution algorithm and BP neural network [J]. Electrical Measurement & Instrumentation, 2020, 57(5): 57-61.
- [15] JIANG J, CHEN R, CHEN M, et al. Dynamic fault prediction of power transformers based on hidden markov model of dissolved gases analysis [J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1393-1400.
- [16] 张阳阳, 黄英, 刘月, 等. 基于多传感器信息融合的人类把握特征学习及物体识别 [J]. 机器人, 2020, 42(1): 267-277.
- ZHANG Y Y, HUANG Y, LIU Y, et al. Human grip feature learning and object recognition based on multi-sensor information Fusion [J]. Robot, 2020, 42(1): 267-277.
- [17] XU N, MAO W, CHEN G D. Multi-interactive memory network for aspect based multimodal sentiment analysis [C]. The Thirty-Third AAAI Conference on Artificial Intelligence (AAAI-19), 2019.
- [18] LIU Y, ZHANG X, HUANG F, et al. Adversarial learning with multi-modal attention for visual question answering [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(9): 3894-3908.
- [19] KUMAR A, VEPA J. Gated mechanism for attention based multi modal sentiment analysis [C]. ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2020.
- [20] LEE J, KIM S, KIM S, et al. Multi-modal recurrent attention networks for facial expression recognition [J]. IEEE Transactions on Image Processing 2020, 29: 6977-6991.
- [21] BERLER Z, GOLUBEV A, RUSOV V, et al. Vibro-acoustic method of transformer clamping pressure monitoring [C]. IEEE International Symposium on electrical Insulation. San Diego, USA: IEEE, 2000.
- [22] YANG J X, YANG F, ZHOU Y X, et al. A data-driven structural damage detection framework based on parallel convolutional neural network and bidirectional gated recurrent unit [J]. Information Sciences, 2021, 566: 103-117.
- [23] JI Y, ZHANG H, JIE Z, et al. CASNet: A cross-attention siamese network for video salient object detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(6): 2676-2690.
- [24] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2019, 16: 4681-4690.
- [25] LI X, WANG W H, HU X L, et al. Selective kernel networks [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) IEEE, 2020.

作者简介



邢致恺, 2015年于佳木斯大学获得学士学位, 2019年于东北林业大学获得硕士学位, 现为武汉大学的博士研究生, 主要研究方向为能源装备的故障诊断及状态评估。
E-mail: xingzk@whu.edu.cn

Xing Zhikai received his B. Sc. degree from Jiamusi University in 2015, M. Sc. degree from Northeast Forestry University in 2019. Now he is Ph. D. candidate in Wuhan University. His main research interests include fault diagnosis method and state assessment of the energy equipment.



何怡刚(通信作者), 1996年于西安交通大学获得博士学位, 现为武汉大学教授, 主要研究方向为混合信号电路故障诊断、电子设备可靠性和通信信道建模与监测等。
E-mail: yghe1221@whu.edu.cn

He Yigang (Corresponding author) received his Ph. D. degree from Xi'an Jiaotong University in 1996. Now he is a professor in Wuhan University. His main research interests include mixed signal circuit fault diagnosis, electronic equipment reliability and communication channel modeling and monitoring.



姚其新, 2002年于华中科技大学获得学士学位, 2010年于华中科技大学获得硕士学位, 现为国网湖北直流公司三级职员, 主要研究方向为特高压直流技术。
E-mail: 15072521848@163.com

Yao Qixin received his B. Sc. degree from Huazhong University of Science and Technology in 2002, M. Sc. degree from Huazhong University of Science and Technology in 2010. Now he is third grade staff of State Grid Hubei DC Company. His main research interest includes UHVDC technology.