

# 基于多源数据融合的 GCB 故障诊断方法<sup>\*</sup>

王兴<sup>1</sup> 张昆<sup>1</sup> 毛雕<sup>1</sup> 刘举<sup>1</sup> 鲍超斌<sup>2</sup> 徐礼荣<sup>3</sup> 陈雅彤<sup>3</sup> 曾晗<sup>3</sup>

(1. 长江电力股份有限公司乌东德电厂 昆明 650000; 2. 武汉启亦电气有限公司 武汉 430000;  
3. 轨道交通基础设施性能监测与保障国家重点实验室 南昌 330013)

**摘要:**提出一种基于自适应卷积权重学习模块和多源数据融合技术的发电机断路器(GCB)故障诊断模型。选择 GCB 设备运行时产生的声纹数据、GCB 两侧基波电压频谱图、特高频局放检测图谱作为 GCB 设备故障诊断的输入数据;对声纹数据进行小波变换,生成声纹时频特征图谱;利用卷积神经网络对各类图像进行特征提取;将提取后得到的特征作为输入信息,输入自适应卷积权重学习的特征融合模块进行特征融合;将融合后的特征输入深度神经网络来进行故障诊断的分类。实验结果表明,所提出的方法故障诊断查准率、查全率和准确率均很高、对复杂的故障环境有着较强的适应能力。

**关键词:**多源数据融合;故障诊断;GCB;自适应卷积;双端接地

**中图分类号:** TM561.3; TN015 **文献标识码:** A **国家标准学科分类代码:** 470.4017

## GCB fault diagnosis method based on multi-source data fusion

Wang Xing<sup>1</sup> Zhang Kun<sup>1</sup> Mao Diao<sup>1</sup> Liu Ju<sup>1</sup> Bao Chaobin<sup>2</sup> Xu Lirong<sup>3</sup> Chen Yatong<sup>3</sup> Zeng Han<sup>3</sup>

(1. Wudongde Power Plant of Yangtze River Power Co., Ltd., Kunming 650000, China;

2. Wuhan Qiyi Electric Co., Ltd., Wuhan 430000, China; 3. State Key Laboratory of Railway

Transportation Infrastructure Performance Monitoring and Assurance, Nanchang 330013, China)

**Abstract:** This paper proposes a GCB fault diagnosis model based on adaptive convolutional weights learning module and multi-source data fusion technology. The sound pattern data generated during the operation of the GCB equipment, the base wave voltage spectrograms on both sides of the GCB, and the UHF localized discharge detection spectra are selected as the input data for the fault diagnosis of the GCB equipment; the wavelet transform is performed on the sound pattern data to generate the time-frequency feature maps of the sound pattern; a convolutional neural network is utilized to perform feature extraction on various types of images; the extracted features are used as the input information, and are fed into the feature fusion module for adaptive convolutional weight learning to perform feature fusion; the fused features are fed into a deep neural network to classify the fault diagnosis. The fusion module is used for feature fusion; the fused features are fed into the deep neural network for classification of fault diagnosis. The experimental results show that the method proposed in this paper has a high fault diagnosis accuracy, completeness and precision rate, and has a strong adaptability to complex fault environments.

**Keywords:** multi-source data fusion; fault diagnosis; GCB; adaptive convolution; double-ended grounding

## 0 引言

发电机断路器(generator circuit breaker, GCB)是连接发电机和升压变压器的有效保护装置,用于控制发电机

线路的通断。GCB 作为一种可靠的集成多功能组合电器,在世界各国得到了较为广泛的应用<sup>[1]</sup>。它采用特定的介质(如 SF<sub>6</sub>)进行灭弧,技术成熟且性能可靠,产品短路开断电流可达较高水平。GCB 特别适用于核电、火电和

收稿日期:2024-10-10

<sup>\*</sup> 基金项目:中国长江电力股份有限公司科研项目(Z522302039)、国家自然科学基金(52277148, 52377103)、轨道交通基础设施性能监测与保障国家重点实验室自主课题(HJGZ2023209)项目资助

水电等大型电厂的更新改造和技术改进项目,对于提高电力系统的安全性和可靠性具有重要意义<sup>[2]</sup>。

目前电力设备故障诊断常用的方法有机械振动法<sup>[3]</sup>、超声波检测法、特高频法局部放电检测法<sup>[4-8]</sup>、红外热像检测法<sup>[9]</sup>、SF6 气体组份及纯度检测法等检测方法。李荷婷等<sup>[10]</sup>根据 GCB 的故障特征,提出了以 GCB 两侧基波零序电压的相角差作为 GCB 非全相保护新型判据的构想,利用对称分量法对 GCB 非全相故障进行了理论分析,运用 PSCAD(power systems computer aided design)软件搭建了 GCB 非全相故障的动态仿真计算模型。

为解决单源信息不完备的问题,研究人员利用由多个传感器信号组成的多源信息获取更加完备的设备健康状态信息,构建多源信息融合模型得到更加稳定可靠的诊断结果。乔卉卉等<sup>[11]</sup>提出了一种适用于变工况轴承故障诊断的多源信息融合网络模型(multi-source information fusion network model, MSIFNM),该模型通过多源信息特征加权模块,使模型自适应地根据不同信号源对不同故障的敏感度差异,实现多源信息特征的自适应加权融合;郝洪涛等<sup>[12]</sup>提出了一种多尺度特征自适应融合网络,设计了权重自适应特征融合网络对多尺度特征加权融合,提高模型对故障特征的表征能力;卢浩龙等<sup>[13]</sup>利用多头自注意力进行特征提取和学习,提高了方法捕捉重要特征的能力;王宸等<sup>[14]</sup>提出了自适应卷积注意力模块(convolutional block attention module-C3, CBAM-C3),CBAM-C3 通过将通道注意力(channel attention module, CAM)和空间注意力(spatial attention module, SAM)相结合加强了对金属齿轮缺陷小目标缺陷自适应的特征学习与特征提取,及时对模型中的权重参数进行学习和优化,提高了模型对小目标缺陷的检测准确度;赵迪等<sup>[15]</sup>提出了一种基于多特征的关键点提取算法和自适应尺度的融合特征的点云配准方法,确保在关键点提取时,同时计算多个特征,使关键点更具描述性和鲁棒性。

庄小亮等<sup>[16]</sup>通过使用梅尔频率倒谱系数(mel-frequency cepstrum coefficient, MFCC)提取声纹信号的特征并构建随机森林对提取的特征信息进行辨识,通过声纹信息来对气体绝缘开关设备(gas insulated switchgear, GIS)动作异常故障进行分类识别。上述方法在 GCB 的故障诊断中具有一定的应用价值,但它们普遍面临信息来源相对单一、适用范围小的局限性,导致在面对多种不同类型的故障时,故障诊断的精度难以达到理想水平。然而,随着神经网络技术的快速发展,深度学习已经在多个领域展现出卓越的性能,并逐步取代了一些传统的故障诊断方法。对于 GCB 的故障诊断而言,深度学习技术通过其强大的特征提取和模式识别能力,实现更高精度的故障检测与诊断。贾卫军等<sup>[17]</sup>通过使用改进卷积神经网络(convolutional neural network, CNN)的深度集成模型,对未训练的局部放电故障数据进行分析 and 迭代,提高了 CNN 模型对局部放电未知故障的检测准确率。但该研究只利用卷

积神经网络进行故障诊断,随着信息源的增加以及输入数据的增多,该网络容易陷入局部最优从而对 GCB 故障诊断不够精确。

综上所述,目前针对 GCB 故障诊断的研究方法存在如下两点局限:1)大部分方法是通过单一数据来源来进行 GCB 故障诊断,这类方法存在一定局限性;2)基于神经网络的 GCB 故障诊断模型所使用的神经网络都是较为早期的神经网络模型,且大多使用结构单一且简单的神经网络模型,得到的结果精度难以满足目前 GCB 故障诊断的精度要求。基于此,本文提出一种基于自适应卷积权重学习模块和多源数据融合技术的 GCB 故障诊断模型。利用多源数据提高模型的分类精度,同时利用自适应卷积权重学习的特征融合模块对特征进行再提取,降低数据的输入量,有效的缓解了因数据量增加神经网络易陷入局部最优的问题,提高了故障诊断精度。

## 1 多源数据预处理

### 1.1 声纹时频特征图谱

近些年来,声纹检测技术广泛用于电力设备检测领域,已经逐渐成为一种适用于各类电力设备的监测、维护、发现隐患以及排查故障的常用技术。

GCB 的声纹信息是时变的非平稳信号,时频域分析能够研究非平稳信号中频率随时间的变化过程。小波分析具有基函数的正交性以及复杂信号具有很高的分辨率等优势,采用连续小波变换(continuous wavelet transform, CWT)绘制时频谱,构建声纹特征图谱。

对声纹时序数据进行分帧以及加窗处理后,对声纹时序数据进行连续小波变换,先确定小波基与尺度,而后求出小波系数,绘制小波系数矩阵即可得到声纹时频特征图谱。

小波变换计算公式如下:

$$T_w(\alpha, \tau) = \frac{1}{\sqrt{\alpha}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t-\tau}{\alpha}\right) dt \quad (1)$$

式中: $x(t)$ 为输入声音信号序列; $\Psi$ 为母小波; $\alpha$ 为尺度因子,决定时频窗的大小; $\tau$ 为平移因子,决定时频窗的位置。

具体实施步骤为先确定小波基函数、尺度因子以及小波的中心频率等参数,然后代入 GCB 声纹信号  $x(t)$  以及小波参数,得到  $x(t)$  的小波系数矩阵  $\mathbf{H}(\alpha, \tau)$  为:

$$\mathbf{H}(\alpha, \tau) = \begin{bmatrix} W(\alpha_1, \tau_1) & W(\alpha_1, \tau_2) & \cdots & W(\alpha_1, \tau_q) \\ W(\alpha_2, \tau_1) & W(\alpha_2, \tau_2) & \cdots & W(\alpha_2, \tau_q) \\ \cdots & \cdots & \cdots & \cdots \\ W(\alpha_p, \tau_1) & W(\alpha_p, \tau_2) & \cdots & W(\alpha_p, \tau_q) \end{bmatrix} \quad (2)$$

式中: $W$ 为小波系数; $\alpha_1, \alpha_2, \dots, \alpha_p$ 分别为第1, 2,  $\dots, p$ 个尺度因子向量; $p$ 为尺度因子向量的长度; $\tau_1, \tau_2, \dots, \tau_q$ 分别为第1, 2,  $\dots, q$ 个平移因子; $q$ 为平移因子向量的程度。

### 1.2 特高频局部放电检测图谱

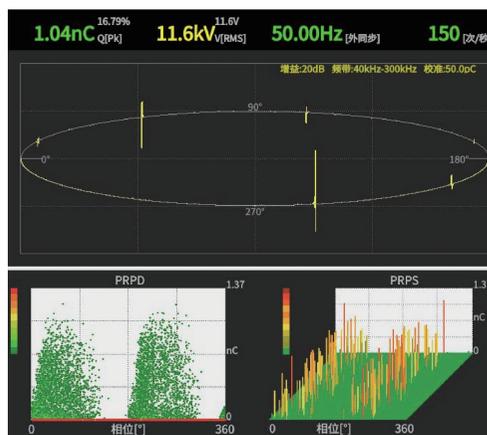
特高频法(ultra-high frequency, UHF)在检测领域有

着高灵敏度、抗干扰能力强、传播距离长、非接触式检测、快速响应等优点,广泛应用于电力系统设备的带电检测中,同样适用于 GCB 的放电检测。

UHF 法能够有效地检测到 GCB 设备中的局部放电故障,并通过分析信号的频谱、幅值和相位等特征参数来判断设备的局部放电情况,从而实现 GCB 设备健康状态的监测和故障的诊断。

通过 UHF 法检测得到的局部放电脉冲相位分布(phase resolved partial discharge, PRPD)图谱,可以直观地展示局部放电活动相对于交流周期 360° 的分布情况,通过分析图谱中的点(代表放电事件)的分布特征,由于每种缺陷类型在 PRPD 图谱上都有其独特的分布模式,所以可以识别出 GCB 中不同的缺陷类型。

还可以观察 PRPD 图谱中放电事件的幅值(Y轴)和数量,可以评估放电的严重程度,其中幅值越大、数量越多的放电事件通常表示更严重的缺陷。PRPD 图谱的 X 轴代表相位角,通过分析放电事件在不同相位角的分布情况,可以了解放电活动的相位特性,这有助于判断放电是发生在单相、两相还是三相中,以及相间活动的情况。各类局部放电脉冲相位分布如图 1 所示。



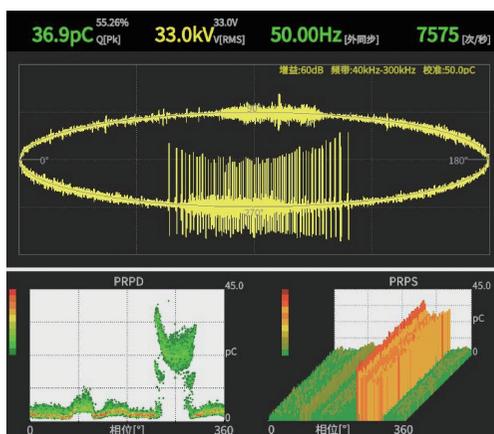
(c) 气隙放电  
(c) Air-gap discharge

图 1 各类局部放电脉冲相位分布

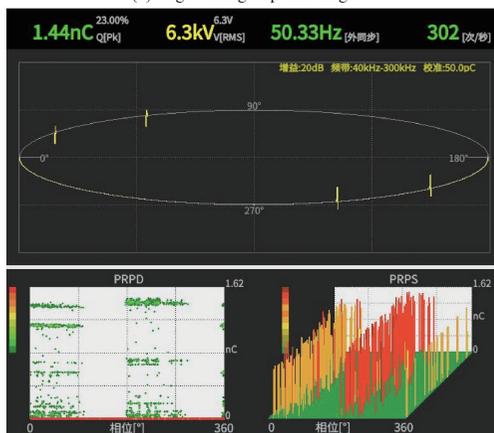
Fig. 1 Phase distribution diagram of various types of partial discharge pulses

## 2 GCB 故障诊断流程

GCB 故障诊断流程如图 2 所示。



(a) 高压尖端放电  
(a) High-voltage tip discharge



(b) 悬浮放电  
(b) Hovering discharge

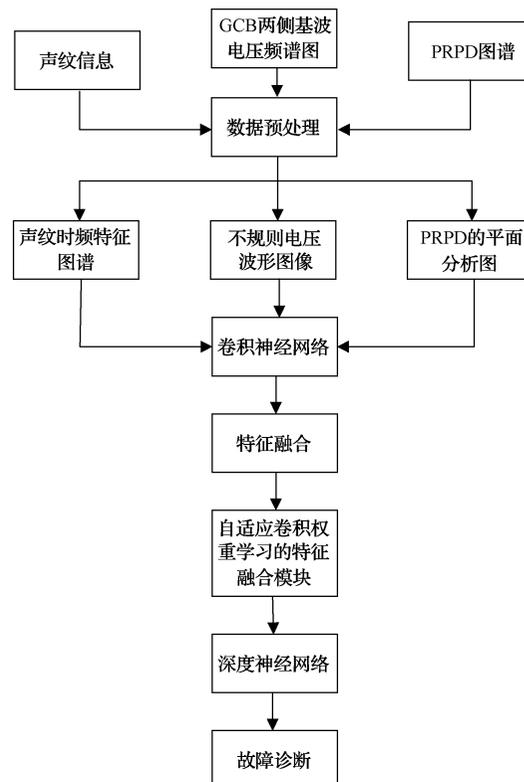


图 2 GCB 故障诊断流程

Fig. 2 GCB troubleshooting process block diagram

1)数据的预处理,对于所述的 3 种来自不同信息源和方法的数据,分别采取不同的数据处理方法。对于声纹时

序数据,仅采用经过小波变换后得到的声纹时频特征图谱作为输入信息;对于GCB两侧基波电压频谱图,将得到的GCB两侧基波电压频谱图进行分割,只保留包含不规则电压波形的部分图像数据作为输入数据;对于特高频局部放电检测图谱,将通过特高频法检测得到的局部放电脉冲相位分布图谱,即PRPD图谱的平面分析图作为输入信息。

2)特征提取,利用CNN对3类大小为 $64 \times 64$ 的特征图谱进行特征提取,得到包含特征的一维向量 $\mathbf{V}_1$ 、 $\mathbf{V}_2$ 和 $\mathbf{V}_3$ 。

3)特征融合,将特征提取得到的向量 $\mathbf{V}_1$ 、 $\mathbf{V}_2$ 和 $\mathbf{V}_3$ 进行合并,得到融合特征向量 $\mathbf{V}_4$ 。

4)将特征融合中得到的特征向量 $\mathbf{V}_4$ 输入至基于自适应卷积权重学习的特征融合模块中,得到最终的融合特征向量 $\mathbf{V}$ ,将得到的融合特征向量 $\mathbf{V}$ 输入深度神经网络(DNN),最后输入至分类层,输出诊断结果,对故障类型和位置进行识别。

对于基于自适应卷积权重学习的特征融合模块,是通过在平均池化层中引入可学习参数,使得池化权重参数可以根据目标域中的特征进行动态更新,以便于更好地筛选和保存经过特征融合后的融合特征向量 $\mathbf{V}_4$ 的特征信息。

基于自适应卷积权重学习的特征融合模块的算法流程如下。

假设输入特征 $X = (x_1, x_2, x_3, \dots, x_j)$ ,  $X$ 为特征集合,  $x_1, x_2, x_3, \dots, x_j$ 为特征向量,自适应池化算法的计算公式为:

$$G(x)_{ij} = \sum_{i,j=1} (\gamma_{ij} x_{ij} + \beta) \quad (3)$$

式中:  $G(x)_{ij}$ 为特征向量经过池化的状态值;  $\gamma_{ij}$ 和 $\beta$ 为池化权重参数;  $x_{ij}$ 为输入的特征向量。

选择Softmax作为分类器,使用交叉熵代价函数计算公式为:

$$L = -\frac{1}{m} \sum_{i=1}^m [y^i \ln(\hat{y}^{(i)}) + (1 - y^i) \ln(1 - \hat{y}^{(i)})] \quad (4)$$

式中:  $y^i$ 为预测输出值;  $\hat{y}^{(i)}$ 为实际标签值;  $L$ 为代价函数;  $m$ 为特征向量的总数。

根据代价函数 $L$ 对参数进行求偏导,进而更新权重参数 $\gamma$ 和 $\beta$ 。

$$\text{初始化池化权重参数 } \gamma \text{ 和 } \beta, \gamma = \begin{bmatrix} 1/41/4 \\ 1/41/4 \end{bmatrix}, \beta = \begin{bmatrix} 0 \\ 0 \end{bmatrix}。$$

利用改进的池化公式计算出每层经过池化后的状态值;

$$G(x)_{ij}^{(l)} = \sum_{i,j=1} [(\gamma_{ij}^{(l)}) x_{ij}^{(l)} + \beta^{(l)}] \quad (5)$$

式中:  $G(x)_{ij}^{(l)}$ 为特征向量在第 $l$ 层经过池化的状态值;  $(\gamma_{ij}^{(l)})$ 和 $\beta^{(l)}$ 为特征向量在第 $l$ 层经过池化的池化权重参数;  $x_{ij}^{(l)}$ 为第 $l$ 层输入的特征向量。

加入非线性因素,  $\alpha^{(l)} = f(G(x)_{i,j}^{(l)})$ , 其中,  $f(G(x)_{i,j}^{(l)})$ 为ReLU激活函数,  $\alpha^{(l)}$ 为第 $l$ 层非线性因素。

计算 $\delta$ ,利用公式反向传播更新公式, ( $\delta$ 为输出值):

$$\delta^{(l)} = -(-y^{(l)} - \alpha^{(l)}) \odot f'(G(x)_{i,j}^{(l)}) \quad (6)$$

式中:  $\delta^{(l)}$ 为第 $l$ 层的输出值;  $y^{(l)}$ 为第 $l$ 层的预测输出值;  $\alpha^{(l)}$ 为第 $l$ 层非线性因素;  $f'(G(x)_{i,j}^{(l)})$ 为ReLU激活函数的导数;  $\odot$ 表示空间乘法运算。

得出 $\delta$ ,从第 $N-1$ 层到第2层依顺序计算池化层的 $\delta$ ,公式为:

$$\delta^{(l)} = ((\gamma^{(l+1)})^T \delta^{(l+1)}) \odot f'(G(x)_{i,j}^{(l)}) \quad (7)$$

式中:  $\delta^{(l)}$ 为第 $l$ 层的输出值;  $(\gamma^{(l+1)})^T$ 为第 $l+1$ 层的权重矩阵的转置矩阵;  $\delta^{(l+1)}$ 为第 $l+1$ 层的输出值;  $f'(G(x)_{i,j}^{(l)})$ 为ReLU激活函数的导数;  $\odot$ 表示空间乘法运算。

计算出当前训练数据的代价函数 $L$ 的偏导数:

$$\nabla_{\gamma^{(l)}} L = \delta^{(l)} (\alpha^{(l-1)})^T \quad (8)$$

$$\nabla_{\beta^{(l)}} L = \delta^{(l)} \quad (9)$$

式中:  $\nabla_{\gamma^{(l)}} L$ 为代价函数 $L$ 的对权重参数 $\gamma$ 的偏导数,  $\nabla_{\beta^{(l)}} L$ 为代价函数 $L$ 的对权重参数 $\beta$ 的偏导数,  $\delta^{(l)}$ 为第 $l$ 层的输出值,  $(\alpha^{(l-1)})^T$ 为第 $l-1$ 层非线性因素矩阵的转置矩阵。

更新参数 $\gamma^{(l)}$ 和 $\beta^{(l)}$ 。

$$\gamma^{(l)} = \gamma^{(l)} - \alpha \nabla_{\gamma^{(l)}} L \quad (10)$$

$$\beta^{(l)} = \beta^{(l)} - \alpha \nabla_{\beta^{(l)}} L \quad (11)$$

式中:  $\nabla_{\gamma^{(l)}} L$ 为代价函数 $L$ 的对权重参数 $\gamma$ 的偏导数,  $\nabla_{\beta^{(l)}} L$ 为代价函数 $L$ 的对权重参数 $\beta$ 的偏导数,  $\beta^{(l)}$ 和 $\gamma^{(l)}$ 为特征向量最终对应的池化权重参数。

利用更新过后的池化参数进行下一次的迭代,直至池化权重参数能够使得代价函数 $L$ 取得最小值;使得池化权重参数可以根据检测得到的数据进行动态更新,能够准确地保留特征信息。

### 3 算例分析

#### 3.1 实验准备

本文实验使用的硬件平台GPU为NVIDIA TX4060,显存为16GB,CPU为i9-14500,内存为32GB,系统环境为Windows,CUDA版本11.1,在PyTorch v2.0.1、Python3.8版本下对模块进行训练、验证。

GCB设备的故障类型主要有操作机构故障(OM)、传动部件磨损(TW)、局部放电故障(PD)、绝缘故障(IF)、电容故障(CF)等,故本文用上述5类故障类型加上无故障状态(NF)作为样本分类的标签。本文数据中的声纹数据主要用来区分操作机构故障和传动部件磨损,基波电压数据主要用来区分绝缘故障和电容故障,UHF数据专门用来检测局部放电故障。可以将数据样本划分为6类,如表1所示。

表 1 GCB 故障分类标签

Table 1 GCB fault classification label

类别	代码
无故障	NF
绝缘故障	IF
电容故障	CF
操作机构故障	OM
传动部件磨损	TW
局部放电	PD

本文的数据均来自某市火力发电厂的 GCB 运行数据,对 GCB 运行数据进行筛选,剔除声纹波形数据中不完整和不连续的部分数据,剔除 PRPD 图谱数据中相对模糊的部分数据,剔除不规则电压波形图像中仅包含规则电压波形图像的部分数据,以防止非故障数据或不完整数据的输入对故障诊断的影响。数据经过筛选与预处理还剩余 2 160 组样本数据,其中含有 420 组声纹数据,580 组基波电压数据和 760 组 UHF 数据。

### 3.2 评价指标

本文通过交叉熵损失函数(CE)、查准率(Pr)、差全率(Re)和准确率(Acc)这 3 个评价指标来反应预测的性能。CE、Pr、Re 和 Acc 的数学表达分别如下所示:

$$loss = \sum_{j=1}^m \sum_{i=1}^n -y_{ij} \log(\hat{y}_{ji}) - (1 - y_{ij}) \log(1 - \hat{y}_{ji}) \quad (12)$$

式中: $m$  为样本量; $n$  为类别数; $\hat{y}_{ji}$  为预测值; $y_{ij}$  为真实值。

$$Pr = \frac{TP}{TP + FP} \quad (13)$$

$$Re = \frac{TP}{TP + FN} \quad (14)$$

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

式中: $TP$  代表真实为正被预测为正的样本数量; $FP$  代表真实为负但被预测为正的样本数量; $FN$  代表真实为正但被预测为负的样本数量。

### 3.3 实验结果与分析

设置 4 种方案分别进行建模分析来证明本文方案的可行性。方案 1 的输入数据集为仅声纹数据,预测模型为自适应卷积权重学习的特征融合模块和 DNN;方案 2 的输入数据集为声纹数据、GCB 两侧基波电压频谱图数据和 UHF 数据,预测模型为 DNN;方案 3 的输入数据集为声纹数据和 GCB 两侧基波电压频谱图数据,预测模型为自适应卷积权重学习的特征融合模块和 DNN;方案 4 的输入数据集为声纹数据、GCB 两侧基波电压频谱图数据和 UHF 数据,预测模型为自适应卷积权重学习的特征融合模块和 DNN。方案对比如表 2 所示。

#### 1) 训练曲线和测试方案研究

针对上述 4 种方案,分别进行建模分析,模型训练的

表 2 GCB 故障诊断模型对比方案

Table 2 GCB fault diagnosis model comparison program

方案	输入数据集	预测模型
方案 1	仅声纹数据	自适应卷积权重学习的特征融合模块+DNN
方案 2	声纹+基波电压+UHF 数据	仅 DNN
方案 3	声纹+基波电压数据	自适应卷积权重学习的特征融合模块+DNN
方案 4	声纹+基波电压+UHF 数据	自适应卷积权重学习的特征融合模块+DNN

迭代次数设置为 500,训练过程中的准确率曲线如图 3 所示。

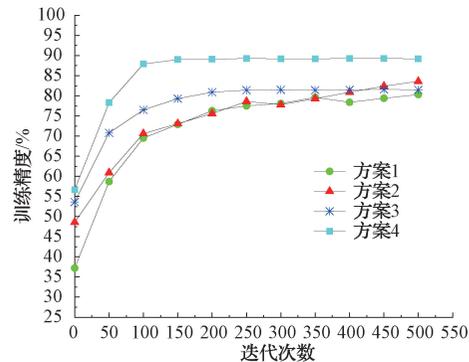


图 3 4 种方案的训练曲线

Fig. 3 Training curves for the four programs

从图 3 可以看出,方案 2 使用了声纹、基波电压、UHF 这 3 种数据,拥有更高的准确率。方案 3 使用了基波电压数据的模型比仅用声纹数据的方案 1 准确率更高。且方案 4 使用多源数据融合和自适应卷积权重学习的特征融合模块的模型在 100 次迭代时已经趋于平稳,而方案 1 使用单一数据的模型在迭代 350 次左右时才趋于平稳,说明使用多源数据融合和自适应卷积权重学习的特征融合模块的模型的收敛速度比用单一数据的模型更快。上述比较说明使用多源数据融合和自适应卷积权重学习的特征融合模块的模型训练效率比仅使用单一数据的模型更高,且使用多源数据融合方法可以有效提高 GCB 故障诊断的分类精度。

可以看出,方案 4 使用包含了自适应卷积权重学习的特征融合模块的模型进行训练在 100 次迭代时就已经收敛,而方案 2 仅使用 DNN 模型进行训练在近 500 次迭代时才收敛,说明经过自适应卷积权重学习的特征融合模块调整后的模型比 DNN 拥有更快的收敛速度;且经过自适应卷积权重学习的特征融合模块调整后的模型比 DNN 的准确率更高,且经过自适应卷积权重学习的特征融合模块调整后的模型在收敛后波动较小。上述比较说明使用

经过自适应卷积权重学习的特征融合模块调整后的模型比DNN的训练效率更高。且使用经过自适应卷积权重学习的特征融合模块调整后的模型可以有效提高对GCB的故障诊断精度。

为了更突出本文提出算法的优势,本文将用交叉熵损失函数、查准率、查全率和准确率4个评价指标来对比上面提到的4个方案的优劣。本文将模型迭代500次得到的结果进行对比,如表3所示。

表3 4种方案对比

Table 3 Comparison table of the four options

方案	CE	Pr/%	Re/%	Acc/%
方案1	0.19	80.63	81.42	80.25
方案2	0.11	84.67	84.86	83.58
方案3	0.16	80.21	80.49	81.51
方案4	<b>0.05</b>	<b>88.72</b>	<b>89.08</b>	<b>89.17</b>

从表3可以看出,本文所提方法的查准率、查全率和准确率分别达到88.72%、89.08%和89.17%均比其他方法高,说明本文所提方法的GCB故障诊断效果较其他方法好,故障判断错误率较低。且本文所提方法的交叉熵损失函数更低,即预测值与实际值的误差值更小,说明本文所提方法的收敛效果更好。本文所提方法有效的在利用多源数据的同时缓解了网络容易陷入局部最优的问题。

2)混淆矩阵研究

对于多分类问题,通常通过混淆矩阵来反映模型的分类效果。

4种方案诊断结果的混淆矩阵如图4所示,其中每个矩阵方格中上面的数字代表当前类别的个数,每个矩阵方格最下面一行代表每个方案的查全率,最右面一列代表每个方案的查准率,最右下角的数字代表准确率。

由4种方案的混淆矩阵可知,方案1仅利用声纹数据进行故障诊断,故每一类的查准率和查全率都较低。方案3在方案1的基础上加入了基波电压数据,因此,对比方

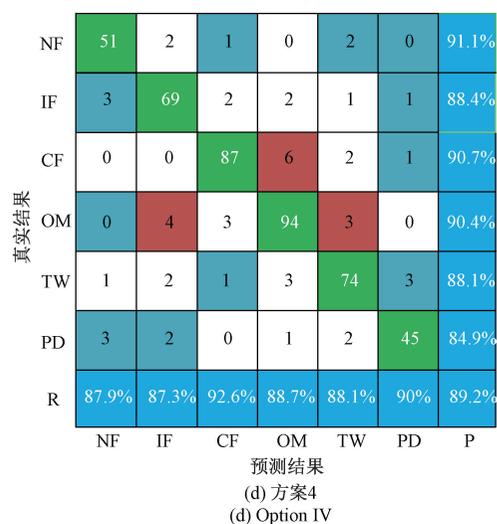
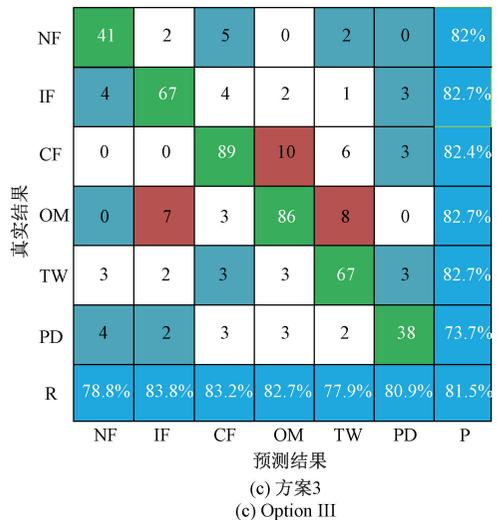
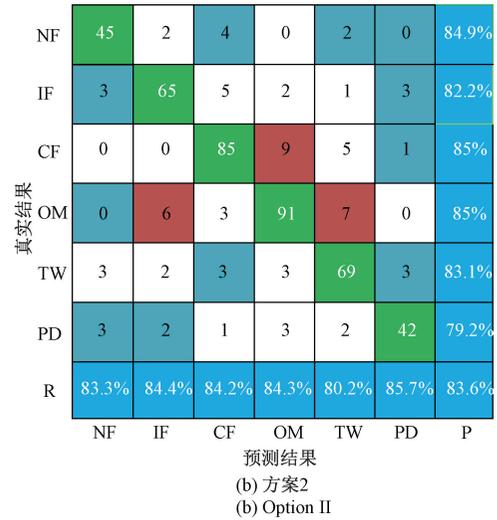
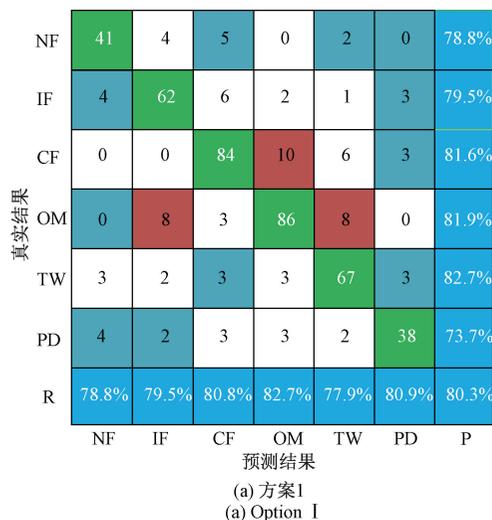


图4 4种方案混淆矩阵

Fig. 4 Confusion matrix of four scenarios

案1,方案3对于绝缘故障和电容故障的故障诊断在查准率和查全率上都有一定提高,但对其他的故障改善较

小。所以方案3的诊断结果精确度依然较低。对比方案1和方案3,方案2将声纹、基波电压、UHF 3类数据作为输入信息来进行诊断。所以,总体的查准率、查全率和精确度都有了提高,说明了使用多源数据融合方法可以有效提高GCB故障诊断的分类精度。但对比方案3和方案1,方案2的诊断结果带来的提升十分有限,各项评价指标均不足85%,总体精确度仍然不是最高。对比方案2,方案4使用经过自适应卷积权重学习的特征融合模块调整后的模型进行故障诊断。总体的查准率、查全率和精确度都有了进一步提高,且所有缺陷的诊断结果均高于87%,说明经过自适应卷积权重学习的特征融合模块调整后的模型能够更加有效结合多源数据的特征来对GCB的故障类型进行分类,进一步提高了GCB故障诊断的查准率、查全率和准确率。

#### 4 结论

针对现有GCB故障诊断研究普遍存在数据来源单一、诊断精度不高和收敛速度较慢等问题,本文提出了一种基于自适应卷积权重学习的特征融合模块和多源数据融合技术的GCB故障诊断模型。本文通过综合考量并融合多种数据特征,显著提升了模型在应对复杂多变环境时的适应性与灵活性。通过使用经过自适应卷积权重学习的特征融合模块调整后的模型对GCB故障进行诊断,有效的结合多源数据的特征来对GCB的故障类型进行分类,进一步提高了GCB故障诊断的查准率、查全率和准确率。

#### 参考文献

- [1] 沙俊强. 大型发电厂电气系统的研究与设计[D]. 北京:华北电力大学,2016.  
SHA J Q. Research and design of large power plant electrical system[D]. Beijing: North China Electric Power University,2016.
- [2] 史天一,张昭宇,张轩瑞,等. GIS缺陷检测用低功耗智能无线振动加速度-声发射融合传感器[J]. 仪器仪表学报,2024,45(5):61-71.  
SHI T Y, ZHANG ZH Y, ZHANG X R, et al. Low-power smart wireless vibration acceleration-acoustic emission combined sensor for GIS defect detection[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 61-71.
- [3] 郝金鹏. 外壳振动信号在GIS故障诊断中的应用研究[D]. 北京:华北电力大学,2016.  
HAO J P. The applied research of shell vibration signal in GIS fault diagnosis [D]. Beijing: North China Electric Power University, 2016.
- [4] 朱超杰,王友臣,朱琪,等. 新型变压器局放监测特高频传感器的研究[J]. 仪器仪表学报,2013,34(4):749-755.
- [5] 王彩雄. 基于特高频法的GIS局部放电故障诊断研究[D]. 保定:华北电力大学,2013.  
WANG C X. Research on partial discharge fault diagnosis in GIS based on UHF[D]. Baoding: North China Electric Power University, 2013.
- [6] 胡义涛,马凯,黄石磊,等. 1000 kV GIS断路器局放带电检测异常分析与处理措施[J]. 高压电器,2024,60(6):80-88.  
HU Y T, MA K, HUANG SH L, et al. Abnormality analysis and treatment of partial discharge live detection of 1000 kV GIS circuit breaker[J]. High Voltage Apparatus, 2024, 60(6): 80-88.
- [7] 李军浩,韩旭涛,刘泽辉,等. 电气设备局部放电检测技术述评[J]. 高电压技术,2015,41(8):2583-2601.  
LI J H, HAN X T, LIU Z H, et al. Review on partial discharge measurement technology of electrical equipment[J]. High Voltage Engineering, 2015, 41(8): 2583-2601.
- [8] 邓东印,柳如见,赵宁波. 一种GIS绝缘拉杆试验装置的改进方法与分析[J]. 电器工业,2024(6):28-31.  
DENG D Y, LIU R J, ZHAO N B. An improved method and analysis of a GIS insulated tie rod test device [J]. China Electrical Equipment Industry, 2024(6):28-31.
- [9] 王生杰,马永福,马国祥,等. 330 kV GIS外壳异常发热机理与改进措施研究[J/OL]. 高压电器,1-11[2024-06-27].  
WANG SH J, MA Y F, MA G X, et al. Research on enclosure overheat mechanism and improvement measures of 330 kV GIS [J/OL]. High Voltage Apparatus, 1-11[2024-06-27].
- [10] 李荷婷,桂林,贺儒飞,等. 基于电压型故障特征量的发电机机端断路器非全相保护[J]. 电力系统自动化,2017,41(1):140-144.  
LI H T, GUI L, HE R F, et al. Voltage features based open-phase protection of generator circuit breaker [J]. Automation of Electric Power Systems, 2017, 41(1): 140-144.
- [11] 乔卉卉,赵二贤,郝如江,等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报,2024,45(9):120-130.

- QIAO H H, ZHAO ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 120-130.
- [12] 郝洪涛, 王凯, 张炳建, 等. 多尺度特征自适应融合的气动控制阀故障诊断[J]. 仪器仪表学报, 2023, 44(10): 167-178.
- HAO H T, WANG K, ZHANG B J, et al. Fault diagnosis of pneumatic control valves with multi-scale features adaptive fusion [J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 167-178.
- [13] 卢浩龙, 朱彦敏. 基于多尺度图 Transformer 的滚动轴承故障诊断[J]. 国外电子测量技术, 2023, 42(12): 186-194.
- LU H L, ZHU Y M. Fault diagnosis of rolling bearing based on multi-scale graph Transformer[J]. Foreign Electronic Measurement Technology, 2023, 42(12): 186-194.
- [14] 王宸, 杨帅, 周林, 等. 基于自适应多尺度特征融合网络的金属齿轮端面缺陷检测方法研究[J]. 电子测量与仪器学报, 2023, 37(10): 153-163.
- WANG CH, YANG SH, ZHOU L, et al. Research on metal gear end-face defect detection method based on adaptive multi-scale feature fusion network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 153-163.
- [15] 赵迪, 赵祖高, 程煜林, 等. 多特征关键点的自适应尺度融合特征点云配准[J]. 电子测量技术, 2023, 46(10): 68-75.
- ZHAI D, ZHAO Z G, CHENG Y L, et al. Adaptive scale fusion feature point cloud registration for multi-feature key points [J]. Electronic Measurement Technology, 2023, 46(10): 68-75.
- [16] 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.
- [17] 贾卫军, 张涛, 李智. 基于改进 CNN 的 GIS 局部放电故障诊断[J]. 信息技术, 2024(3): 90-97.
- JIA W J, ZHANG T, LI ZH, et al. GIS partial discharge fault diagnosis based on improved CNN[J]. Information Technology, 2024(3): 90-97.

#### 作者简介

王兴, 工程师, 主要研究方向为电气一次设备检修与维护。

E-mail: 1994830366@qq.com

陈雅彤(通信作者), 硕士, 主要研究方向为电力设备故障检测。

E-mail: 1193068400@qq.com