

DOI: 10.13382/j.jemi.B2407886

多注意力残差脉冲神经网络的接地网故障诊断*

闫孝姮 丁一凡 陈伟华 张雪

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要:针对目前接地网故障诊断方法效果单一与非智能化的问题,提出了一种多注意力残差脉冲神经网络(MAR-SNN)的接地网故障诊断方法。首先,创建用于训练的接地网数据集,通过对电阻抗成像技术(EIT)网格大小的重新剖分,提高成像速度,并利用局部自适应对比度增强方法,增强不同故障等级间的图像特征;其次,利用所提出的多注意力脉冲残差块,构建MAR-SNN模型,实现对接地网故障等级的识别任务,该残差模块通过在两次脉冲神经元后进行身份映射,同时引入多注意力机制,并采用参数-泄露-积分-触发脉冲神经元与批归一化层,分别提升模型识别准确率;最后,利用EIT与训练好的MAR-SNN模型,建立对接地网故障的智能诊断模型。模型对比分析结果表明, MAR-SNN在接地网智能故障诊断中的效果优于现有先进模型,在测试集中准确率可达96.31%,其中在轻、中腐蚀程度下的准确率可达100%、97.20%;同时实验结果证明,所提方法可以完成对接地网故障检测与等级识别的综合诊断任务,实现对接地网的智能故障诊断,验证了该方法的有效性与可行性。

关键词: 接地网智能故障诊断;多注意力残差;脉冲神经网络;电阻抗成像技术;对比度增强

中图分类号: TN06;TP183

文献标识码: A

国家标准学科分类代码: 510.40

Multi-attention residual spiking neural network-based grounding grid fault diagnosis

Yan Xiaoheng Ding Yifan Chen Weihua Zhang Xue

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

Abstract: In this paper, a multi-attention residual spiking neural network (MAR-SNN)-based grounding grid fault diagnosis method is proposed to deal with the existing single and unintelligent problems in the diagnosis of grounding grid. Firstly, creating the grounding grid dataset for training, using the electrical impedance tomography (EIT) after re-meshing to improve imaging speed and enhancing image features between different fault levels by using the local adaptive contrast enhancement method; Secondly, the MAR-SNN model is built by a new multi-attention spiking residual block is proposed to realize the intelligent fault diagnosis of grounding grid. The residual block performs identity mapping after two spiking neurons, adopts PLIF spiking neurons and BN layer, and introduces multi-attention mechanism to improve the accuracy of model recognition separately; Finally, using EIT and the trained MAR-SNN model to construct the intelligent fault diagnosis model of grounding grid. The comparative analysis of the models shows that the performance of MAR-SNN is superior to the existing advanced models, and in the test set the accuracy is 96.31%. Among them, the accuracy of mild and medium corrosion degree can reach 100% and 97.20% respectively. At the same time, the experimental results show that the proposed method can realize the intelligent fault diagnosis of grounding grid including fault detection and level identification, so verify the effectiveness and feasibility of the method.

Keywords: intelligent fault diagnosis of grounding grid; multi-attention residuals; spiking neural network; electrical impedance tomography; contrast enhancement

0 引言

接地网是保障电力系统安全的关键设施^[1],由于长时间埋于地下,其可能因为施工缺陷和土壤腐蚀而性能受损^[2]。因此,对接地网定期进行故障诊断是必不可少的。目前对接地网故障的研究主要分为两大类,一类是故障检测,即检测出接地网的故障位置;另一类是故障诊断,即在检测的基础上诊断出当前接地网的故障等级。

电阻抗成像技术(electrical impedance tomography, EIT)由于快速、便携、非侵入、低成本、无辐射等优点^[3]被引入到接地网故障检测领域。文献[4]提出了一种内源式 EIT 实现对接地网故障的检测,同时利用改进正则化的牛顿-拉夫逊迭代方法来对 EIT 逆问题进行求解。文献[5-6]在接地网 EIT 模型的基础上,分别提出了吉洪诺夫正则化和全变差正则化相结合的混合正则化算法、同伦-吉洪诺夫正则化算法来改善 EIT 逆问题中的病态性,提升接地网 EIT 收敛性与成像清晰度。文献[7]提出了一种 L1-L2 弹性范数算法对接地网逆问题进行修正,提高了腐蚀检测的准确性,但成像速度不快。文献[8]提出了一种优化微分-多重网格-同伦算法,在保证接地网 EIT 成像稳定性的同时,大幅度提升了成像速度。虽然当前 EIT 在接地网故障检测中有着可观的应用效果,但复杂的有限元剖分限制了 EIT 进一步通过数学运算来量化接地网故障等级。在接地网故障诊断方面,文献[9]通过支路电阻对支路电压扰动理论分析,建立电压扰动与腐蚀状态之间的映射关系,再利用计算与绘图对接地网进行腐蚀支路定位与腐蚀程度评估。文献[10-11]分别在接地网电网络法的基础上提出基于 Lasso 理论与改进灰狼算法对故障诊断方程的求解进行改进,进而实现对接地网的腐蚀诊断。文献[12]利用支路电阻变化对端口灵敏度的规律优化诊断模型,实现凝聚层次聚类的接地网定向支路减维腐蚀诊断。基于接地网模型诊断方程的故障诊断方法,除欠定方程求解难题外,尚存在诊断过程复杂、计算量大、不智能等问题。为了避免传统故障诊断模型中的复杂计算,人工智能被引入故障诊断中。文献[13]通过激光诱导击穿光谱从不同腐蚀样品中收集光谱数据,结合机器学习进行接地网腐蚀程度评估。文献[14]在接地网电磁感应方法的基础上,利用所建磁场断电数据集训练一维卷积神经网络实现对杆塔接地网的断点诊断。

当前人工神经网络(artificial neural network, ANN)在不断发展中展现了较好的性能,但其本质上还是通过非线性函数与权重进行大规模数据运算,拟合特征的一种数学表达,神经学科在其中的应用逐渐减弱。因此,一个高精度的 ANN 需要大量的能量消耗,在工业应用中仍

具有一定的局限性。于是利用脉冲传递处理信息的脉冲神经网络(spiking neural network, SNN)更加类似于高能效率的生物神经系统,被称为第 3 代神经网络。由于 SNN 的高生物合理性、神经芯片部署的低能耗性、时空信息的高处理能力^[15]使 SNN 作为一种有效工具,被引入到智能故障诊断领域。文献[16]提出了一种宽脉冲残差分组注意力框架用于智能故障诊断任务。文献[17-18]分别提出深度脉冲残差收缩网络、基于特征融合的 SNN,用于轴承故障诊断。文献[19]将随机共振与深度脉冲残差网络结合应用于滚动轴承的故障诊断。文献[20]提出了一种多维度注意力机制的脉冲神经网络模型用于无人机射频信号分类,与故障诊断任务相似。智能故障诊断任务模型摒弃了物理模型的复杂计算,是一种智能、便捷的数据驱动方法,只需根据不同诊断对象收集相应数据来驱动模型实现端到端的诊断任务。接地网从整体来看与文献[16-20]的诊断对象无异,均为智能故障诊断的应用端;而具体到接地网智能故障诊断模型,则需根据接地网的数据特征,进行数据增强并构建相对应的高性能诊断模型。

鉴于此,本文保留 EIT 在接地网故障检测中的成像优势,以此作为数据驱动,拓展其在接地网智能故障诊断中的应用,提出一种新的 SNN 模型——多注意力残差脉冲神经网络(multi-attention residual spiking neural network, MAR-SNN),实现接地网的智能故障诊断。通过重新剖分网格大小后的 EIT 提高成像速度,构建不同故障等级、个数、分布的接地网数据集,同时利用局部自适应对比度增强(locally adaptive contrast enhancement, LACE)方法加强接地网故障特征,得到强对比度的接地网数据集,最后利用数据集训练由多注意力脉冲残差块(multi-attention spiking residual block, MASRB)搭建的 MAR-SNN 模型实现对接地网故障的等级分类。该方法分别通过 EIT 与 MAR-SNN 完成对接地网的故障检测与等级判别任务,得以实现对接地网的智能故障诊断。大量模型对比分析与实验结果表明,本文所提方法的有效性与可行性。

1 基于 MAR-SNN 的接地网智能故障诊断方法描述

本文所提出的基于 MAR-SNN 的接地网智能故障诊断方法,在 EIT 基础上,引入 SNN 以数据驱动实现对接地网的智能故障诊断。主要包含接地网数据集创建、图像增强、网络搭建与训练、智能故障诊断 4 部分,其基本框图如图 1 所示。

1) 接地网数据集创建

深度学习的训练过程需要大量且全面的数据作为支




图1 基于 MAR-SNN 的接地网智能故障诊断方法框图

Fig. 1 The block diagram of MAR-SNN-based grounding grid intelligent fault diagnosis

撑。面对接地网的故障诊断任务,一个故障等级分类清晰、故障情况全面的数据集是必不可少的。然而现有故障诊断方法获取接地网数据流程复杂,同时在获取实际接地网数据时,接地网的故障情况不可控且只有单一输出结果,因此,获得一个充分全面的实际接地网数据集困难重重。基于上述问题,提出一种基于 EIT 技术的接地网数据集创建方法,EIT 技术通过电阻率成像,在仿真过程中,可以清晰划分接地网不同故障等级电阻变化范围,同时对 EIT 网格重新进行剖分,提升成像速度。因此使用 EIT 可以有效地创建一个具有不同故障等级、不同故障个数、不同故障位置的接地网数据集。

2) 图像增强

基于 MAR-SNN 的接地网智能故障诊断方法,利用数据驱动实现对接地网故障等级的判别。因此,数据增强可提升 MAR-SNN 网络的判别精度。在接地网数据集中,故障与非故障的对比度为主要特征,因此,本文采用 LACE 对所创建的接地网数据集进行对比度增强处理,1)和2)部分共同完成强对比度接地网数据集的创建。

3) 网络搭建与训练

搭建高性能诊断模型,实现对接地网故障程度的智能判别。本研究分别在 SNN 基本网络结构深度、脉冲神经元、归一化层、注意力机制结构等方面进行改进。通过大量对比训练,验证所创 MASRB 结构搭建出的 MAR-SNN 模型判别准确率最高,最适用于接地网故障诊断任务。同时 MAR-SNN 模型可在 Spikingjelly^[15] 框架上直接训练并输出接地网的故障等级。

4) 智能故障诊断

利用 EIT 与训练后 MAR-SNN 实现对接地网的智能故障诊断,首先获取待诊断的接地网电压;其次利用电压数据获得 EIT 图像并进行 LACE 处理得到强对比度接地网成像图;最后 MAR-SNN 模型可根据成像图直接诊断出接地网当前的故障程度。本文研究提出的基于 MAR-SNN 的接地网智能故障诊断方法可以在对接地网故障位置可视化的基础上智能诊断出接地网的故障等级,如轻、中、重腐蚀,断裂等,并在电阻与扁钢接地网模型中得到实验验证,为接地网智能故障诊断提供了一种新思路。

2 强对比度接地网数据集创建

2.1 接地网 EIT 原理与方法

1) 接地网 EIT 正问题

接地网 EIT 利用电阻率成像反映接地网情况,即获取逆问题的结果成像,实际的 EIT 逆问题求解在正问题的基础上完成。接地网 EIT 正问题关系可表示为:

$$\Phi = h(\rho) \quad (1)$$

式中: Φ, ρ 分别代表电位值与电阻率的矩阵形式; h 表示一种非线性的映射关系。EIT 的正问题通常采用有限元法来实现。在有限元模型中,接地网边值问题的等价变分问题为:

$$F(\phi) = \sum_{e=1}^N \int_{S_e} \frac{1}{2} \sigma \left[\left(\frac{\partial \phi}{\partial x} \right)^2 + \left(\frac{\partial \phi}{\partial y} \right)^2 \right] dx dy \quad (2)$$

式中: S_e 表示第 e 个单元的面积; N 表示场域剖分的单元个数。

根据三角单元中任意点电位和该单元各顶点电位值之间的关系,式(2)在第 e 个单元上的泛函式可用矩阵表示为:

$$F_e(\phi) = \frac{1}{2} [\Phi]_e^T [K]_e [\Phi]_e \quad (3)$$

式中: $[\Phi]_e$ 为三角单元顶点电位矩阵, $[K]_e$ 为第 e 个单元的单元系数矩阵,只与电阻率(或电导率)有关。有限元总系数矩阵可用单元系数矩阵合成,于是有限元方程为:

$$[K][\Phi] = 0 \quad (4)$$

采用列主元消去法求解有限元方程即可得到各节点

上的电位,完成 EIT 正问题的求解过程。

2) 接地网 EIT 逆问题

在接地网 EIT 的逆问题中,问题变为根据测量参数 ϕ 得到模型参数 ρ ,而在实际中由于各种误差的存在,逆问题无法得到精确解,于是 EIT 的逆问题转变为,利用最小二乘法构建近似解,使得待求模型参数 ρ 满足:

$$\boldsymbol{E}(\boldsymbol{\rho}) = \operatorname{argmin} \| \boldsymbol{h}(\boldsymbol{\rho}) - \boldsymbol{V} \|^2 \tag{5}$$

式中: $\boldsymbol{E}(\boldsymbol{\rho})$ 为误差函数,表示计算电压与实际测量电压之间的误差; $\boldsymbol{V}$ 表示实际测量电压。在本文研究中,接地网 EIT 逆问题选用优化微分的多重网格同伦算法^[8],该算法在保证逆问题结果稳定性的前提下,大大提升了求解速度,适用于大量数据集的创建。

2.2 接地网数据集创建

1) 接地网模型与网格剖分

在电力系统中接地网面积大且形状不固定,针对大型接地网通常采用区域诊断,精确度高且适用性广。因此,本文所建数据集的接地网模型为 3×3 的网格结构,图 2 所示分别为扁钢接地网与仿真接地网的模型结构。




图 2 接地网模型结构

其中,扁钢接地网模型中每个网格长度 0.5 m,宽度 0.05 m,厚度 0.004 m,电导率为 6×10^6 S/m,电阻率为 $1.67 \times 10^{-7} \Omega \cdot \text{m}$,根据扁钢模型尺寸电阻可求为 $8.35 \times 10^{-4} \Omega$;土壤电阻率为 $200 \Omega \cdot \text{m}$,仿真接地网模型大小按照扁钢接地网模型建立。接地网 EIT 的仿真通过 COMSOL 与 MATLAB 联合实现。

在接地网 EIT 逆问题中,不同的剖分单元大小会影响成像结果与成像速度。理论上,网格剖分越细代表对接地网处理越细致,但会增大计算成本、牺牲成像速度,于是采取合适的网格剖分大小至关重要。图 3 所示为 4 种不同网格剖分单元所对应的成像图与运行时间,可以看出网格剖分数 $N=2$ 时,成像图既保留了接地网的基本信息且故障特征明显,同时又保证了较快的成像速度。因此,选用 $N=2$ 的网格剖分。

2) 接地网数据集等级划分与分布

构建用于接地网故障诊断的数据集,需要有清楚的




图 3 不同网格剖分大小与运行时间对比

Fig. 3 Comparison of different grid size and running time

故障等级划分标准,根据电力行业标准《接地网腐蚀诊断技术导则》^[21] 规定,本研究补充断裂情况,将接地网故障等级划分为 4 类,如表 1 所示。

表 1 接地网数据集不同故障等级划分标准

Table 1 Different fault level classification standard of grounding grid dataset

腐蚀程度	轻腐蚀	中腐蚀	重腐蚀	断裂
接地网支路电阻增大倍数	0~1	2~9	>9	
土壤与接地网支路电阻率比值				1~20

根据不同故障等级的电阻范围,均匀设定故障支路电阻参数,同时,在每种故障等级下设置不同的故障数量与位置。本文研究所建接地网数据集,每种故障等级各 2 000 张图像,总计 8 000 张图像,其中,接地网故障数量平均设置为 1~4,故障位置在接地网不同行列分布。图 4 为所建接地网数据集示例图片。

2.3 数据集图像增强

为增强图像特征,改善图像识别效果,需对数据集做增强处理,针对故障诊断任务特点,图像对比度为本研究数据集的增强重点。近年来,图片增强方法在水下图片增强领域得到广泛发展^[22],受其对图片对比度增强的启发^[23],本文采用 LACE 方法得到强对比度接地网数据集,LACE 在 CIELab 颜色空间中进行局部图像块操作,通过在 L 通道增强对比度,a、b 通道平衡颜色差异来增强局部图像的对比度。

1) L 通道的局部对比度增强

通过局部图像块的均值与方差来调整 L 通道的强




图4 接地网数据集示例图片

Fig. 4 Grounding grid dataset sample pictures

度,为避免对比度的欠、过度增强问题与复杂耗时的计算过程,引入积分图与平方积分图来计算局部图像块的均值与方差。以局部图像块A举例,其宽为 W ,高为 H ,左上角点坐标为 (x_1, y_1) ,灰度矩阵为 $L_A(x, y)$ 。

图5所示为局部图像块A的L通道积分图。




图5 L通道积分图

Fig. 5 L channel integral diagram

在积分图中A中像素点之和只需要4个顶点的值即可得到,则A的均值计算公式为:

$$\mu_A = \frac{\sum_{y=y_1}^{y_1+H-1} \sum_{x=x_1}^{x_1+W-1} L_A(x, y)}{H \times W} = \frac{p_4 - p_2 - p_3 + p_1}{H \times W} = \frac{I_A}{H \times W} \quad (6)$$

式中: $p_1 \sim p_4$ 分别表示积分图中4点的值; I_A 表示局部图像块A积分图的值。方差同理在平方积分图中计算,局部块A的方差计算公式为:

$$\sigma_A = \frac{I_A^2}{H \times W} - \mu_A^2 \quad (7)$$

将局部图像块的均值作为低频分量,则输入图像减去低频分量为高频分量,通过增加高频分量来提高图像对比度。则L通道的局部对比度增强公式为:

$$L_{EA}(x, y) = \mu_A + \frac{\sigma_G}{\sigma_A} (L_A(x, y) - \mu_A), \forall (x, y) \in A(x, y) \quad (8)$$

其中, $L_{EA}(x, y)$ 表示A增强后的L通道值, σ_G 为全图方差,定义 $\frac{\sigma_G}{\sigma_A}$ 为高频分量的控制因子,并设定截止上限为2。

2) a、b通道的色彩平衡

通过a、b通道的色彩平衡对颜色进行补偿,其独立于L通道,在a、b颜色通道中的平均值为:

$$\bar{I}_c = \frac{\sum_{y=1}^H \sum_{x=1}^W I_c(x, y)}{H \times W}, c \in \{a, b\} \quad (9)$$

平衡过程为:

$$I_{bc} = I_b + \frac{\bar{I}_a - \bar{I}_b}{\bar{I}_a + \bar{I}_b} \cdot I_b, \bar{I}_a > \bar{I}_b \quad (10)$$

$$I_{ac} = I_a + \frac{\bar{I}_b - \bar{I}_a}{\bar{I}_a + \bar{I}_b} \cdot I_a, \bar{I}_a < \bar{I}_b \quad (11)$$

其中, I_{bc} 、 I_{ac} 为颜色平衡后的 a、b 颜色通道。强对比度接地网数据集示例图如图 6 所示。




图 6 接地网数据集 LACE 前后对比

Fig. 6 Comparison of grounding grid dataset before and after LACE

3 接地网故障诊断 MAR-SNN 模型建立

本文提出了 MASRB 来构建 MAR-SNN 模型。MAR-SNN 是可直接训练的 SNN 模型,在脉冲残差神经网络框架上,采用参数-泄露-积分-触发 (parametric leaky integrate and fire, PLIF) 脉冲神经元、批归一化 (batch normalization, BN) 层增强模型对接地网故障诊断的适用性,并引入多注意力机制进一步提升对接地网故障诊断的准确率。

3.1 脉冲残差神经网络

残差网络 (residual network, ResNet) 仍旧是当前最流行的网络架构之一,当前最先进的 SNN 改进与应用大多基于 ResNet 架构。经典的脉冲残差块直接用脉冲神经元代替 ANN 中的激活函数,仍旧存在些许退化问题。本研究采用身份映射内双脉冲神经元的脉冲要素模块^[24] (spike-element-wise-block, SEW-Block) 结构,能顺利的完成残差训练,并进一步解决 SNN 中的梯度消失与爆炸问题,进而提升接地网故障诊断的准确性,当残差块的输入与输出维度不同时,残差连接中需要下采样结构。图 7 所示为带有下采样结构的经典脉冲残差块与 SEW-Block 的对比,其中 SN 表示脉冲神经元, x 与 $s(t)$ 表示残差块输入, F 表示残差块从输入到残差连接之间的作用关系, $A(t)$ 表示 $s(t)$ 与 $F[s(t)]$ 之间的函数关系,本研究中选用相加的函数关系。




图 7 带有下采样的残差块对比

Fig. 7 Comparison of residual blocks with downsampling

3.2 脉冲神经元

脉冲神经元是 SNN 中的关键组成部分也是关键特征,只能输出脉冲信号即 0 或 1。脉冲神经元是有状态、有记忆的,其状态变量一般指膜电位。脉冲神经元的行为可以通过充电、放电与复位 3 个过程来描述,离散方程分别如式 (12) ~ (14) 所示。

$$H[t] = f(V[t-1], X[t]) \quad (12)$$

式中: $H[t]$ 表示神经元充电后,放电前的膜电位, $V[t-1]$ 表示前一时刻末的膜电位, $X[t]$ 表示外源输入, $f(V[t-1], X[t])$ 整体表示神经元的状态更新方程。

$$S[t] = \varepsilon(H[t] - V_{\text{threshold}}) \quad (13)$$

式中: $S[t]$ 表示 t 时刻的输出脉冲, $V_{\text{threshold}}$ 表示神经元的阈值电压,一般设为 1,其中 $\varepsilon(x)$ 表示阶跃函数。

$$V[t] = \begin{cases} H[t] \cdot (1 - S[t]) + V_{\text{reset}} \cdot S[t], & \text{hard reset} \\ H[t] - V_{\text{threshold}} \cdot S[t], & \text{soft reset} \end{cases} \quad (14)$$

式中: $V[t]$ 表示 t 时刻的膜电位, 即复位电位, V_{reset} 为重置电压, 不同的脉冲神经元放电与复位方程可共享。

本文采用 PLIF 脉冲神经元^[25], PLIF 与常见的积分-触发 (integrate and fire, IF) 与泄露-积分-触发 (leaky integrate and fire, LIF) 神经元不同, 可对膜时间常数 τ 进行学习, τ 可以在训练过程中自动优化, 增加了 SNN 对初始值的鲁棒性; 同时 PLIF 在不同层内神经元的膜时间常数不同, 更好的表示了神经元的异质性。PLIF 的充电方程为:

$$H[t] = V[t-1] + \frac{1}{\tau}(X[t] - (V[t-1] - V_{\text{reset}})) \quad (15)$$

式中: $\frac{1}{\tau} = \text{Sigmoid}(w)$, 其中 w 可训练。

3.3 MASRB 与 MAR-SNN 模型

本文设计的 MASRB 以 SEW-Block 为底层结构进行改进, 采用 PLIF 脉冲神经元与 BN 层, 其中残差结构与

BN 层均是 SNN 中逼近 ANN 性能的有效手段。SNN 同时对时间与空间信息具有强大的处理能力, 为了同时增强对时空中重要信息的提取, 进一步提升接地网故障判别的准确率, 分别引入时间注意力机制 (temporal-wise-attention, TA)、通道注意力机制 (channel-wise-attention, CA) 与 TA、CA 联合起来的时间-通道注意力机制 (temporal-channel-wise-attention, TCA), 设计多注意力结构。

MASRB 中的多注意力结构分别在模块的不同位置添加对于接地网故障诊断任务有效的注意力机制。在 SNN 处理多时刻信息时, 时间步长是重要参数, 于是首先, 在首个 2 维卷积层 (convolutional-2d layer, Conv2d) 后插入 TA, 增强对时间通道信息的处理, 提升学习效率; 其次, 在第 1 个 BN 层后引入 TCA, 集中对时间与通道信息的联合处理, 提升故障诊断效果; 最后, 在模块后续的 BN 与 Conv2d 层后分别加入 TA, 不断优化时间维度信息, 进一步提升模型对接地网的故障诊断性能。图 8 所示为 MASRB 的基本结构与 TA、CA、TCA 的基本工作原理。




图 8 MASRB 框架图

Fig. 8 MASRB frame diagram

可以看出, 在 TA 中, 通过对输入进行平均与最大池化, 只保留时间维度信息并进行卷积, 再 Sigmoid 处理两

个结果之和, 得到时间维度的权值与原输入相乘得到注意力后的时间维度信息。CA 原理与 TA 相似, 池化后只

保留通道维度信息,进而获得通道的权值,与原输入相乘后得到注意力后的通道维度信息。TCA 将 TA 与 CA 连

接起来,将 TA 输出作为 CA 的输入。

各个注意力机制计算公式如式(16)所示。

$$\begin{cases} TA_{out} = s(t) \times \text{Sigmoid}(\text{Avgpool}(T(s)) + \text{Maxpool}(T(s))) \\ CA_{out} = s(t) \times \text{Sigmoid}(\text{Avgpool}(C(s)) + \text{Maxpool}(C(s))) \\ TCA_{out} = TA_{out} \times \text{Sigmoid}(\text{Avgpool}(C(s)) + \text{Maxpool}(C(s))) \end{cases} \quad (16)$$

式中:Avgpool 为平均池化;Maxpool 为最大池化。

同组成,其结构与功能如图 9 所示。

MAR-SNN 模型由脉冲编码层、MASRB 与分类层共




图 9 接地网智能故障诊断模型 MAR-SNN

Fig. 9 MAR-SNN intelligent fault diagnosis model of grounding grid

其中,MAR-SNN 模型的前 3 层作为脉冲编码层可自动完成对图片的脉冲编码,因此模型可以直接输入接地网的成像图片;MASRB 以脉冲形式传递信息作为模型的主要特征提取与处理成分;最后全连接层作为模型的分层,根据脉冲发放率完成对接地网故障等级的分类。

4 MAR-SNN 模型对比分析

现将本研究所设计的 MAR-SNN 模型的每一步改进过程与当前先进模型进行对比分析,本文所有脉冲神经网络的训练均在 Spikingjelly 框架上完成,数据集按 8:2 的比例划分为训练集与测试集,网络训练保留 SNN 中的时间步长参数,采用多步模式,后端选用“cupy”加快训练速度,网络评价指标分别选用准确率与损失函数。准确率计算公式分别如式(17)、(18)所示。

$$\text{总体准确率 (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

$$\text{单一准确率 (Precision)} = \frac{TP}{TP + FP} \quad (18)$$

式中:TP 与 TN 分别表示对正负预测正确的值;FP 与 FN

分别表示对正负预测错误的值。

损失函数选用均方差损失函数(mean squared error, MSE)来衡量预测值和真实值之间的平均差异,其公式为:

$$MSE = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N} \quad (19)$$

式中: N 为样本个数; y_i 与 $\hat{y}_i$ 分别为真实值与预测值。

4.1 不同脉冲神经网络框架对比分析

MAR-SNN 在残差网络的基础上进行改进,现分别对 Parametric-Net^[25]、Spiking-VGG11^[26]、经典的 Spi king-Resnet18^[27]、采用 SEW-Block 的 SEW-Resnet18、SEW-Resnet19^[26]、SEW-Resnet34^[24] 6 个基本网络框架进行训练,对比其在接地网故障诊断中的性能。

在对比不同基本网络框架的性能时,为展示不同基本框架间的原始差异,在此基础上不做任何改进,同时,训练过程中均选用常见的 LIF 脉冲神经元与对比度增强前的原始数据集。图 10 所示为测试过程中的准确率与损失函数,6 种基本框架的最佳准确率与所对应的损失函数如表 2 所示。




图 10 不同 SNN 框架的测试结果
Fig. 10 Test results of different SNN frameworks

综上训练结果表明,选用 SEW-Block 的 SEW-Resnet 系列网络效果较好,但是网络深度的增加针对于本研究的应用对象没有明显效果,于是 MAR-SNN 选用表现最好的 SEW-Resnet18 作为基本框架。

表 2 不同 SNN 框架的最佳测试结果
Table 2 The best test results of different SNN frameworks

序号	网络结构	训练准确率/%	损失函数
1	Parametric-Net	93.31	0.032
2	Spiking-VGG11	93.50	0.030
3	Spiking-Resnet18	94.19	0.025
4	SEW-Resnet18	94.69	0.024
5	SEW-Resnet19	94.38	0.025
6	SEW-Resnet34	94.19	0.026

4.2 强对比度与原接地网数据集对比分析

为了验证 LACE 在接地网故障诊断中的提升效果,在选定的 SEW-Resnet18 框架下,对比处理前后数据集在接地网智能故障诊断中的效果,测试准确率与损失函数如图 11 所示,最佳准确率与所对应的损失函数如表 3




图 11 数据集处理前后的测试结果
Fig. 11 Test results before and after dataset processing

根据训练结果可知 LACE 有效增强了接地网 EIT 图像中的故障特征,提升了接地网故障诊断的准确率。

表 3 数据集处理前后的最佳测试结果
Table 3 The best test results before and after dataset processing

序号	网络结构	LACE	训练准确率/%	损失函数
1	SEW-Resnet18	无	94.69	0.024
2	SEW-Resnet18	有	95.31	0.020

4.3 不同脉冲神经元的结果对比分析

脉冲神经元作为 SNN 的关键特征,不同的工作方式会对 SNN 的性能造成不同的影响。研究在强对比度接地网数据集与 SEW-Resnet 基本框架上分别对比常见的简单脉冲神经元 IF、LIF、PLIF^[25]、脉冲表征的微分方法 (differentiation on spike representation, DSR)^[28]、融合不同神经元生物特征的门控泄露-积分-触发脉冲神经

元 (gated leaky integrate- and-fire neuron, GLIF)^[29]。训练准确率与损失函数如图 12 所示,最佳准确率与所对应的损失函数如表 4 所示。




图 12 不同脉冲神经元的测试结果
Fig. 12 Test results of different spiking neurons

表 4 不同脉冲神经元的最佳测试结果				
Table 4 The best test results of different spiking neurons				
序号	网络结构	神经元	训练准确率/%	损失函数
1	SEW-Resnet18	IF	95.25	0.021
2	SEW-Resnet18	LIF	95.31	0.020
3	SEW-Resnet18	PLIF	95.81	0.018
4	SEW-Resnet18	DSR	95.44	0.021
5	SEW-Resnet18	GLIF	95.00	0.023

根据训练结果可知 MAR-SNN 模型中选用的 PLIF 神经元,在接地网故障诊断中的性能最佳。

4.4 不同批归一化的对比分析

批归一化层对于网络训练尤为重要,本研究在使用 PLIF 神经元的 SEW-Resnet18 框架上,分别对比原始 BN 层、阈值相关的批归一化方法 (threshold-dependent batch normalization, TDBN)^[30] 与时间有效批归一化方法

(temporal effective batch normalization,TEBN)^[26],训练准确率与损失函数如图 13 所示,最佳准确率与所对应的损失函数如表 5 所示。




图 13 不同批归一化层的测试结果
Fig. 13 Test results of different batch normalization layers

表 5 不同批归一化层的最佳测试结果				
Table 5 The best test results of different BN layers				
序号	网络结构	批归一化层	训练准确率/%	损失函数
1	SEW-Resnet18 (PLIF)	BN	95.81	0.018
2	SEW-Resnet18 (PLIF)	TEBN	95.19	0.021
3	SEW-Resnet18 (PLIF)	TDBN (0.7, 0.5)	95.13	0.022
4	SEW-Resnet18 (PLIF)	TDBN (1, 1; 0.7, 1)	95.75	0.020

以上对比均采用强对比度接地网数据集进行训练,根据训练对比结果可知 BN 层在接地网故障诊断中的效果,为 3 种批归一化层中最佳。

4.5 不同注意力机制模块的对比分析

注意力机制是深度学习中提升模型能力的一种有效方法^[31],现将本研究设计的包含多注意力残差结构的 MAR-SNN,分别与其他采用单一注意力机制 TA、CA、空间注意力机制 (spatial attention, SA);简单多维注意力机

制 TCA、时间-空间注意力机制 (temporal-spa-tial-wise-attention, TSA)、通道-空间注意力机制 (channel-spatial-wise-attention, CSA)、时间-通道-空间注意力机制 (temporal-channel-spatial-wise-attention, TCSA) 与多维融合注意力机制^[32] (temporal-channel joint attention, TCJA) 进行对比,训练结果如图 14 所示,最佳准确率与所对应的损失函数如表 6 所示。




图 14 不同注意力机制的测试结果

Fig. 14 Test results of different attention mechanisms

表 6 不同注意力机制的最佳测试结果

Table 6 The best test results of different attention mechanisms

序号	网络结构	训练准确率/%	损失函数
1	TA-SNN	95.81	0.019
2	CA-SNN	95.5	0.019
3	SA-SNN	94.75	0.022
4	TCA-SNN	95.88	0.019
5	TSA-SNN	94.94	0.022
6	CSA-SNN	94.94	0.024
7	TCSA-SNN	95.88	0.018
8	TCJA-SNN	91.06	0.035
9	MAR-SNN	96.31	0.017

根据训练的结果对比可知,本文所设计的 MAR-SNN 模型中的多注意力机制结构在接地网故障诊断中准确率最高,明显优于其他常用注意力机制,同时最终构建好的 MAR-SNN 模型在强对比度接地网数据集上,可使接地网智能故障诊断的准确率达到 96.31%。

4.6 MAR-SNN 模型在接地网故障诊断中的诊断效果

经过以上的训练对比,验证了所提方法的有效性。接地网不同故障个数成像图之间会有一定的特征差异,而 MAR-SNN 可在接地网 1~4 个不同故障数量的综合数据集上,实现准确率达 96.31% 的故障诊断效果。

MAR-SNN 完成对接地网的智能故障诊断时,只需将待诊断的接地网图像输入到已经训练好的 MAR-SNN 模型,便可直接输出诊断故障等级。SNN 通过脉冲的发放率来代表输出特征,发放率取整,最大值所属等级代表模型诊断出的故障等级,按位置输出诊断的接地网故障等级标签。图 15 与表 7 为诊断效果示例。




图 15 MAR-SNN 接地网故障诊断输出图像

Fig. 15 Fault diagnosis output image of grounding grid image based MAR-SNN

表 7 MAR-SNN 诊断结果

Table 7 Fault diagnosis results of MAR-SNN

编号	真实故障等级	脉冲发放率	诊断故障等级
		Firing rate	
a	轻腐蚀	[0 1 0 0]	轻腐蚀
b	中腐蚀	[0 0 1 0]	中腐蚀
c	重腐蚀	[0 0 0 1]	重腐蚀
d	断裂	[1 0 0 0]	断裂

综上可看出,本文提出的基于 MAR-SNN 的接地网智能故障诊断方法可以通过图像可视化接地网故障位置,并输出当前故障等级。MAR-SNN 在训练集与测试集

表 9 实验故障诊断结果

Table 9 Experimental fault diagnosis results

序号	真实故障等级	脉冲发放率	诊断故障等级
		Firing rate	
19-a	轻腐蚀	[0 1 0 0]	轻腐蚀
19-b	中腐蚀	[0 0 1 0]	中腐蚀
19-c	重腐蚀	[0 0 0 1]	重腐蚀
19-d	断裂	[1 0 0 0]	断裂
20-a	轻腐蚀	[0 1 0 0]	轻腐蚀
20-b	断裂	[1 0 0 0]	断裂

6 结 论

针对目前接地网故障诊断研究效果单一、故障等级分类不清晰、诊断过程复杂与不智能等问题,本文提出一种基于 MAR-SNN 的接地网智能故障诊断方法。该方法利用 EIT 构建接地网数据集来训练所搭建的 MAR-SNN 模型,将 EIT 与 SNN 结合起来实现对接地网的智能故障诊断,诊断结果既能可视化接地网故障位置又能输出当前接地网的故障等级。研究中对 EIT 网络进行重新剖分以提升成像速度,并采用 LACE 增强数据集对比度特征,提升图像识别效果;针对接地网对象特点提出 MASRB 模块搭建 MAR-SNN 模型,该模型在残差脉冲神经网络基础上改进,保留了 SNN 本身作为三代神经网络更具有生物合理性的优点,所设计的多注意力机制结构对注意力机制的合理安排使得模型对接地网故障诊断的性能进一步提高,并采用在接地网故障诊断中表现效果最佳的 PLIF 脉冲神经元与 BN 层。大量仿真结果表明 MAR-SNN 在接地网故障诊断中准确率最高,可达 96.31%,同时电阻与扁钢接地网模型的实验结果证明所提方法的有效性。本文提出的基于 MAR-SNN 的接地网智能故障诊断方法,为接地网的智能故障诊断提供了一种新思路。但在重腐蚀与断裂状态下的诊断效果有待下一步提升。

参考文献

[1] 马成廉,宋萌清,尹波,等. 结合 IEEE std80-2000 和 CDEGS 的变电站新建接地网优化设计研究[J]. 电力系统保护与控制, 2024, 52(24): 131-139.
MA CH L, SONG M Q, YIN B, et al. Optimizing the design of a new substation grounding network by combining IEEE std80-2000 and CDEGS [J]. Power System Protection and Control, 2024, 52 (24): 131-139.

[2] 王玥,张卫欣,王崇,等. 基于多重网格剖分技术的智能变电站接地网电磁响应数值模拟研究[J]. 电测与仪表, 2024, 61(12): 97-103.
WANG Y, ZHANG W X, WANG CH, et al. Study on numerical simulation of electromagnetic response of

intelligent substation grounding grid based on multi-grid partitioning technology [J]. Electrical Measurement & Instrumentation, 2024, 61(12): 97-103.

[3] CHEN Z, XIANG J, BAGNANINCHI P O, et al. MMV-Net: A multiple measurement vector network for multifrequency electrical impedance tomography [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(11): 8938-8949.

[4] 李星,杨帆,余晓,等. 基于内源式电阻抗成像的接地网缺陷诊断逆问题研究[J]. 电工技术学报, 2019, 34(5): 902-909.
LI X, YANG F, YU X, et al. Research on the inverse problem of grounding grid fault diagnosis based on inner-source EIT [J]. Transactions of China Electrotechnical Society, 2019, 34(5): 902-909.

[5] 闫孝姮,吕秋皓,林晓雪,等. 基于 Tikhonov 和 TV 混合正则化的接地网电阻抗成像算法研究[J]. 仪器仪表学报, 2021, 42(11): 160-171.
YAN X H, LYU Q H, LIN X X, et al. Research on grounding grid electrical impedance tomography algorithm based on tikhonov and TV hybrid regularization [J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 160-171.

[6] 闫孝姮,林晓雪,吕秋皓,等. 基于 Homotopy-Tikhonov 算法的接地网电阻抗成像方法[J]. 电工技术学报, 2022, 37(9): 2284-2294.
YAN X H, LIN X X, LYU Q H, et al. Grounding grid electrical impedance tomography based on homotopy-tikhonov algorithm [J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2284-2294.

[7] 张维哲,张承乾,刘建生,等. 基于弹性范数的接地网电阻抗成像算法[J]. 电工技术学报, 2025, 40(3): 676-688.
ZHANG W ZH, ZHANG CH Q, LIU J SH, et al. Grounding grid electrical impedance tomography algorithm based on elastic norm [J]. Transactions of China Electrotechnical Society, 2025, 40(3): 676-688.

[8] YAN X H, HUANG S F, SMOLIK W T, et al. A detection method for fast electrical impedance imaging of grounding grid based on optimized differential-multigrid-homotopy algorithm [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72(328714): 1-14.

[9] 董曼玲,李星,杨帆,等. 基于支路电压扰动的接地网腐蚀缺陷诊断研究[J]. 高压电器, 2021, 57(8): 47-53.

- DONG M L, LI X, YANG F, et al. Study on corrosion defects diagnosis of grounding grid based on branch voltage disturbance[J]. *High Voltage Apparatus*, 2021, 57(8): 47-53.
- [10] 程宏波, 钟文帆, 陈艳华, 等. 一种基于 Lasso 理论的牵引变电所接地网腐蚀诊断方法[J]. *铁道学报*, 2024, 46(5): 58-65.
- CHENG H B, ZHONG W F, CHEN Y H, et al. Research on corrosion diagnosis of grounding grid based on lasso theory [J]. *Journal of The China Railway Society*, 2024, 46(5): 58-65.
- [11] 李友才, 李晓龙, 罗周维, 等. 基于改进灰狼算法的接地网腐蚀诊断方法[J]. *电瓷避雷器*, 2024(5): 100-109.
- LI Y C, LI X L, LUO ZH W, et al. Corrosion diagnosis method of grounding grid based on improved gray wolf algorithm[J]. *Insulators and Surge Arresters*, 2024(5): 100-109.
- [12] 谢场, 杨鑫, 黄亚飞, 等. 基于凝聚层次聚类的接地网定向支路减维腐蚀诊断优化方法[J]. *高电压技术*, 2024, 50(4): 1723-1730.
- XIE Y, YANG X, HUANG Y F, et al. Optimization method for dimension-reduction corrosion diagnosis of directional branch of grounding grid based on condensation hierarchical clustering [J]. *High Voltage Engineering*, 2024, 50(4): 1723-1730.
- [13] HUANG Z C, XIA L Y, ZHANG H, et al. Evaluation of grounding grid corrosion extent based on laser-induced breakdown spectroscopy (LIBS) combined with machine learning [J]. *Computers and Electrical Engineering*, 2024, 120(109849): 1-11.
- [14] 孙绍珩, 鲁彩江, 曹中清, 等. 基于深度学习的杆塔接地网断点诊断方法研究[J]. *电子测量与仪器学报*, 2021, 35(10): 168-175.
- SUN SH H, LU C J, CAO ZH Q, et al. Research on diagnosis method of tower grounding grid breakpoints based on deep learning [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35 (10): 168-175.
- [15] FANG W, CHEN Y Q, DING J H, et al. SpikingJelly: An open-source machine learning infrastructure platform for spike-based intelligence [J]. *Science Advances*, 2023, 9(40): 1-18.
- [16] LIU J L, WANG H. A brain-inspired energy-efficient wide spiking residual attention framework for intelligent fault diagnosis [J]. *Reliability Engineering and System Safety*, 2024, 243(109873): 1-13.
- [17] XU Z T, MA Y M, PAN Z K, et al. Deep spiking residual shrinkage network for bearing fault diagnosis [J]. *IEEE Transactions on Cybernetics*, 2024, 54(3): 1608-1613.
- [18] XU Z Z, CHEN X, XU J T. Multi-modal multi-sensor feature fusion spiking neural network algorithm for early bearing weak fault diagnosis [J]. *Engineering Applications of Artificial Intelligence*, 2025, 141(109845): 1-10.
- [19] ZHANG X Q, MA Y M, PAN Z K, et al. A novel stochastic resonance based deep residual network for fault diagnosis of rolling bearing system [J]. *ISA Transactions*, 2024, 148: 279-284.
- [20] SI Z, LIU C, LIU J Y, et al. Application of SNNs model based on multi-dimensional attention in drone radio frequency signal classification [C]. *ICASSP-2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Seoul, 2024: 231-235.
- [21] 国家能源局. 中华人民共和国电力行业标准: DL/T1532-2016[S]. 北京: 中国电力出版社, 2016.
- National Energy Administration. English translation of People's Republic of China Electric Power Industry standard: DL/T1532-2016 [S]. Beijing: China Electric Power Press, 2016.
- [22] LIU R S, JIANG Z Y, YANG S Z, et al. Twin adversarial contrastive learning for underwater image enhancement and beyond [J]. *IEEE Transactions on Image Processing*, 2022, 31: 4922-4936.
- [23] ZHANG W D, ZHUANG P X, SUN H H, et al. Underwater image enhancement via minimal color loss and locally adaptive contrast enhancement [J]. *IEEE Transactions on Image Processing*, 2022, 31: 3997-4010.
- [24] FANG W, YU Z F, CHEN Y Q, et al. Deep residual learning in spiking neural networks [C]. *35th Conference on Neural Information Processing Systems (NeurIPS 2021)*, 2021: 21056-21069.
- [25] FANG W, YU Z F, CHEN Y Q, et al. Incorporating learnable membrane time constant to enhance learning of spiking neural networks [C]. *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, 2021: 2641-2651.
- [26] DUAN C T, DING J H, CHEN S Y, et al. Temporal effective batch normalization in spiking neural networks [C]. *36th Conference on Neural Information Processing Systems (NeurIPS 2022)*, New Orleans, 2022: 34377-34390.

[27] HU Y F, TANG H J, PAN G. Spiking deep residual networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(8): 5200-5205.

[28] MENG Q Y, XIAO M Q, YAN S, et al. Training high-performance low-latency spiking neural networks by differentiation on spike representation [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, 2022: 12444-12453.

[29] YAO X T, LI F R, MO Z T, et al. GLIF: A unified gated leaky integrate-and-fire neuron for spiking neural networks [C]. 36th Conference on Neural Information Processing Systems (NeurIPS 2022), New Orleans, 2022: 32160-32171.

[30] ZHENG H L, WU Y J, DENG L, et al. Going deeper with directly-trained larger spiking neural networks[C]. The Thirty-Fifth AAAI Conference on Artificial Intelligence (AAAI-21), 2021, 12: 11062-11070.

[31] DU Z T, ZHOU X C, LYU M N, et al. Multi-scale attention dilated residual image denoising network based on skip connection[J]. Instrumentation, 2024, 11(3): 41-53.

[32] ZHU R J, ZHAO Q H, DENG H Y, et al. TCJA-SNN: Temporal-channel joint attention for spiking neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(3):5112-5125.

作者简介



闫孝恒, 2005 年于辽宁工程技术大学获得学士学位, 2008 年于辽宁工程技术大学获得硕士学位, 2016 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学教授, 主要研究方向为电磁探测与成像。

E-mail: xiaohengyan@163.com

Yan Xiaoheng received her B. Sc. degree from Liaoning Technical University in 2005, M. Sc. degree from Liaoning Technical University in 2008, and Ph. D. degree from Liaoning Technical University in 2016, respectively. Now she is a professor in Liaoning Technical University. Her main research interests include electromagnetic detection and imaging.



丁一凡, 2021 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要方向为接地网电阻抗成像与脉冲神经网络。

E-mail: yifanding00325@163.com

Ding Yifan received her B. Sc. degree from Liaoning Technical University in 2021. Now she is a M. Sc. candidate in Liaoning Technical University. Her main research interests include electrical impedance tomography of grounding grid and spiking neural network.