

基于 LSTM-CNN 特征融合和 BO-SVM 的 GIS 绝缘缺陷识别研究

谢醉冰¹, 马龙涛¹, 王吉利¹, 曾林平¹, 牛浩天², 田毅²

(1. 国家电网有限公司西北分部, 陕西 西安 710050; 2. 西安工程大学 西安市电气设备互联感知与智能诊断重点实验室, 陕西 西安 710048)

摘 要: 气体绝缘组合开关设备 (GIS) 内部绝缘缺陷引发局部放电时会产生多种特征信号。然而现场通常处于复杂的工况, 伴随着较大的噪声环境, 从而增加了信号处理和故障诊断的难度。为解决上述问题, 提出一种长短时记忆网络 (LSTM) 融合卷积神经网络 (CNN) 与贝叶斯优化支持向量机 (BO-SVM) 相结合的融合模型来实现 GIS 绝缘故障诊断。首先, 将局部放电产生的原始超声信号和特高频信号同时传入 LSTM 和 CNN 通道。通过 LSTM 对一维时序信号和 CNN 对一维时序信号到二维信号转换后的图像信号进行特征指纹提取, 并将两种特征值在 CNN 的融合层进行融合。最后, 将执行后的结果输入进 BO-SVM 分类层, 使用 BO 对支持向量机 (SVM) 的核函数 γ 和惩罚参数 C 进行迭代, 得到最优解。相比较传统的单一通道进行特征值提取的方式, 所提出的方法在准确性、鲁棒性等方面都取得了显著的进展, 准确率达 97.5%。为在复杂环境下 GIS 绝缘故障识别提供了可靠的解决方案。

关键词: 气体绝缘组合开关设备; 绝缘缺陷; 局部放电; 特征指纹; 融合模型; 缺陷分类

DOI: 10.15938/j.emc.2025.12.016

中图分类号: TM85

文献标志码: A

文章编号: 1007-449X(2025)12-0182-13

Study of GIS insulation defect identification method using LSTM-CNN feature fusion and BO-SVM

XIE Zuibing¹, MA Longtao¹, WANG Jili¹, ZENG Linping¹, NIU Haotian², TIAN Yi²

(1. Northwest Branch of State Grid Corporation of China, Xi'an 710050, China; 2. Xi'an Key Laboratory of Interconnected Sensing and Intelligent Diagnosis for Electrical Equipment, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: Multiple characteristic signals are generated when partial discharge is caused by internal insulation defects in gas insulated switchgear (GIS). However, field conditions are often complex, with significant noise interference. In such challenging scenarios, collected signals are prone to noise interference, increasing the difficulty of signal processing and fault diagnosis. To address these challenges, a GIS insulation fault diagnosis method was proposed combining long short term memory (LSTM) with convolutional neural network (CNN) and Bayesian optimization for support vector machines (BO-SVM). The original ultrasonic and ultra-high-frequency signals generated by partial discharge were simultaneously fed into

收稿日期: 2024-08-26

基金项目: 国家电网有限公司西北分部科技项目 (SGNW0000SJJS2310368)

作者简介: 谢醉冰 (1988—), 男, 硕士, 高级工程师, 研究方向为智慧电网、电力系统调度运行及控制;

马龙涛 (1988—), 男, 硕士, 高级工程师, 研究方向为智慧电网、电力系统调度运行及控制;

王吉利 (1981—), 男, 博士, 高级工程师, 研究方向为智慧电网、电力系统调度运行及控制;

曾林平 (1970—), 男, 学士, 高级工程师, 研究方向为输变电设备在线监测与故障诊断;

牛浩天 (2000—), 男, 硕士研究生, 研究方向为电力设备智能感知与故障诊断;

田毅 (1984—), 男, 博士, 教授, 研究方向为电力设备智能感知与故障诊断。

通信作者: 田毅

both the LSTM and CNN channels. Feature fingerprints extraction was performed from one-dimensional temporal signals using LSTM and image signals converted from one-dimensional temporal signals to two-dimensional signals using CNN, and the two types of feature values were fused in the fusion layer of CNN. Finally, the executed results were input into the BO-SVM classification layer, and the kernel function γ and penalty parameter C of support vector machines (SVM) were iterated using BO to obtain the optimal solution. Compared to traditional methods that extract features using a single channel, the proposed approach demonstrates significant advancements in terms of accuracy and robustness. The results show that the LSTM-CNN feature fusion and BO-SVM model exhibit notable advantages in insulation recognition performance, achieving an accuracy of 90.34%. This method provides a reliable solution for GIS insulation fault identification based on ultrasonic and ultra-high-frequency signals in complex environments.

Keywords: gas insulated switchgear; insulation defects; partial discharge; feature fingerprint; aggregation models; defect classification

0 引言

在气体绝缘组合开关设备(gas insulated switchgear, GIS)的整个运行过程中,由于不当操作、绝缘老化等因素导致设备内部产生绝缘缺陷^[1-2]。这些缺陷一定程度上会诱发局部放电(partial discharge, PD),若不能及时发现并采取适当的措施加以修复,绝缘缺陷在 PD 的影响下逐渐恶化,最终可能引发绝缘击穿事故,造成广泛停电,带来重大经济损失。目前,对 GIS 设备内部缺陷的诊断技术包括机械检测、诊断性试验、SF₆ 气体泄漏诊断等。局部放电是主要诊断特征,常用方法有超声波、特高频与分解产物法等^[3-5]。GIS 设备内的主要绝缘缺陷是金属突出物、绝缘子气隙、绝缘子表面金属污秽多,这是由于在生产、运输、安装过程中不规范操作遗留或运行过程中产生的^[6]。GIS 内部的绝缘缺陷会引起局部放电,局部放电发生时,放电点周围的气体出现振荡变化过程,会产生具有一定特征的声波信号和射频信号^[7]。目前对于 GIS 内部绝缘缺陷的检测主要是通过超声或特高频单一传感器进行。单一传感提取检测信号容易忽略动态放电信号中的非平稳信号的特征和被背景噪声干扰,从而造成关键信息缺失、识别分类准确率低和鲁棒性低等问题。准确辨识不同绝缘缺陷产生的局部放电类型有利于制定准确高效的检修策略。超声融合特高频能有效综合两种信号的评估信息,相比独立信息评估具有更佳的评估性能、更高的准确率和可靠性。因此利用各种绝缘缺陷产生的超声信号和特高频信号,对 GIS 故障的辨识以及缺陷隐患具有重要意义,有助于提高电力系

统的可靠性和稳定性。

随着人工智能技术的迅速发展,大量的机器学习方法被引入到 GIS 绝缘缺陷识别中,如卷积神经网络、支持向量机等,取得了显著进展^[8-16]。机器学习能够自动提取数据集中的特征,减少对专业先验知识的需求。单一的机器学习方法也存在弊端,如神经网络能够很好地提取二维图像数据特征指纹,但在时序信号处理方面传统神经网络忽略了数据的时间依赖性,其长期依赖关系的建模相对困难,故难以捕捉一维时序信号特征指纹^[17-18]。近几年随着大语言模型技术不断发展,模型融合作为一种低成本、高性能的机器学习模型构建方法得到了快速发展。相比较于开发新的训练模型,融合现有深度学习模型具有更高的性价比,且可以产生更为先进的深度学习模型。

针对现有 GIS 绝缘缺陷识别中机器学习方法的问题以及模型融合的优势,本文提出一种基于多层融合特高频和超声数据分析的 GIS 设备绝缘缺陷诊断方法。首先,基于 126 kV 等比例缩小的 GIS 开展了 5 种绝缘缺陷模拟试验。其次,本文采用长短时记忆网络(long short term memory, LSTM)处理一维时序信号融合卷积神经网络(convolutional neural network, CNN)处理二维图像信号的方式,以提取 GIS 中的特征指纹。综合利用两者,更有效地提取数据集中的特征指纹。随后在 CNN 的融合层将这两种特征进行融合的方式进行特征值的提取。最后,采用经过贝叶斯优化(Bayesian optimization, BO)后的支持向量机(support vector machines, SVM)作为分类工具对 GIS 绝缘故障类型进行分类。

本文所提融合模型具备以下优点:

1) 提出一种超声波传感器、特高频传感器融合的 GIS 设备绝缘缺陷诊断方法。利用归一化处理得到灰度图的方式将多种传感器采集到的时序数据转换成图像特征图谱,形成超声、特高频融合特征图谱。

2) 本研究模型融合 LSTM 提取一维时序信号特征及 CNN 处理二维图像特征,通过 CNN 内部融合层整合两者信息,既深度挖掘了一维信号的内在特征,又通过 CNN 分析了二维灰度图像中非连续区域间的局部关联性,从而实现对不同 GIS 绝缘缺陷特征全面而立体的提取。

3) 本文将经过优化处理的 BO-SVM 算法应用于 GIS 绝缘缺陷模式分类任务中,从而增强了诊断模型对复杂工况下绝缘缺陷识别的精准度和可靠性。通过该优化方法,模型能够更深层次地挖掘潜在绝缘缺陷特征并区分不同的故障。

1 实验平台

图 1 是试验罐体,其按照实际运行的单相 126 kV GIS 腔体进行等比例缩小设计而成。实验罐体采用三段式同轴圆柱结构,最右侧段是实验罐体的高压实验段,长约 58.5 cm,内半径为 6.2 cm,罐体壁厚为 2.2 cm;第二段罐体用于支撑高压导电杆和安装气阀,长约 17.5 cm,白色圆环形支撑件为聚四氟乙烯材质,起到支撑绝缘子作用;最左侧段罐体采用绝缘材料尼龙制作,起到高压进线套管的作用,长约 15 cm。整个罐体的连接处均装有氟橡胶密封圈,可以承受 8 倍大气压的压强。实验中使用纯度 99.999% 的 SF_6 气体,所加气体压力控制为 6 个大气压。另外,为了保证实验与现场运行工况的一致性,如图 1 所示,设置施加工频电压 48 kV,两者腔体内的电场分布基本一致。

GIS 内部 PD 造成电子碰撞从而产生大量的超声波信号。同时当 PD 发生时,其快速放电特性导致产生的脉冲具有多种频率成分,其中特高频 (ultra-high frequency, UHF) 信号沿着设备腔体传播到四周。UHF 检测是通过在 GIS 法兰处安装特高频传感器,捕获 PD 产生的 300 ~ 3 000 MHz 频段射频信号。与其他方法相比,UHF 检测能够避开电力系统中电晕现象所引起的低频带电磁波影响。因此本文同时采集超声和特高频信号。




图 1 GIS 等比例缩小试验罐体

Fig. 1 GIS tank body with proportional reduction

设备信号检测装置包括:鹏翔 PXR04I 超声波传感器(频率带宽为 30 ~ 140 kHz、谐振频率为 40 kHz)、40 dB 固定增益 100 倍放大器、阿尔泰 USB-8812H 数据采集卡(设置采样率为 90 kHz);天威 TWUHF-G04 特高频传感器(200 MHz ~ 2 GHz)、特高频检波模块(通过在实验室和现场测试,发现 GIS 实际运行中的局放特征频谱主要集中在 400 ~ 1 000 MHz,在 1 GHz 以上只存在少量的局放特征频谱,因此本文选择的检测频率为 400 ~ 1 000 MHz,输出频率小于 1 M,此频带避开电子设备干扰频段,也是放电信号灵敏度最高频带)和阿尔泰 PCIe-8916M 数据采集卡(模拟带宽 100 MHz)。上位机开发软件采用 LabVIEW,信号采集系统如图 2 所示。




图 2 信号采集系统

Fig. 2 Signal acquisition system

根据国际大电网会议统计 GIS 内部绝缘缺陷分为 5 种:悬浮电位缺陷(Ⅰ类缺陷)、绝缘子表面污秽放电(Ⅱ类缺陷)、金属突出物(Ⅲ类缺陷)、绝缘子气隙缺陷(Ⅳ类缺陷)和自由金属颗粒缺陷(Ⅴ类缺陷),上述各缺陷如图 3 所示。




图 3 GIS 设备绝缘缺陷类型示意图

Fig. 3 Types of insulation faults in GIS equipment

悬浮电位缺陷是运行中的断路器及隔离开关在机械操作振动时会导致部件移位或随时间积累产生老化,都易引起导体接触不良出现悬浮电位,本文在实验中采用将高压母线固定的螺栓更换为小一号并在两侧垫绝缘颗粒从而模拟螺丝松动导致的悬浮电位。绝缘子表面污秽缺陷主要为 GIS 中一些金属碎末或颗粒长期滞留在绝缘子表面,最终固定粘附形成的固定金属附着物,本文在实验中选择将铜屑作为金属碎末粘附在绝缘子表面从而模拟绝缘子表面附着污染。金属突出物模拟由于不良加工、机械原因或安装时刮擦等引起的金属毛刺,本文将长不超过 2 cm 的不同长度的针电极(主要是不同毫米级针电极)焊接在高压母线和 GIS 外壳内侧从而在实验中模拟低压侧和高压侧金属突出物。绝缘子气隙缺陷用以模拟在浇铸绝缘子时或设备长期运行振动、机械力等原因,致使绝缘子内存有气泡、绝缘子内产生裂纹或绝缘子与高压导体接触处存有空隙的情况。通过对气隙缺陷尺寸对于产生缺陷信号的测试以及考虑到实验室的加工精度,本文在实验中通过在绝缘子上钻小孔(孔径小于 0.5 cm),并用环氧树脂将孔表面封住,凝固后形成绝缘子气隙缺陷。自

由金属微粒缺陷是由于在生产、安装过程中,清洁不够仔细或设备长期运行振动在 GIS 内部产生的碎屑,本文采用长度不超过 0.1 mm 的铝制碎屑在实验中模拟该缺陷。

2 方法理论

2.1 长短时记忆神经网络(LSTM)

网络的每层由多个 LSTM 细胞组成,而每个 LSTM 细胞的内部结构如图 4 所示。图中:方框 I 表示遗忘门;方框 II 表示输入门;方框 III 表示输出门。遗忘门、输入门和输出门的数学表达式为:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f); \quad (1)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i); \quad (2)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o); \quad (3)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c x_t + U_c h_{t-1}) + b_c; \quad (4)$$

$$h_t = o_t \tanh(c_t). \quad (5)$$

式中: x_t 、 c_t 和 h_t 是时间步 t 的输入向量、更新的记忆细胞激活向量和隐藏状态激活向量; i_t 是输入门在时间步 t 的激活向量; f_t 是遗忘门在时间步 t 的激活向量; o_t 是输出门在时间步 t 的激活向量; W_i 、 W_f 、 W_c 、 W_o 是输入门、遗忘门、更新记忆细胞、输出门的输入内核; U_i 、 U_f 、 U_c 、 U_o 是输入门、遗忘门、更新记忆细胞、输出门的循环内核; b_i 、 b_f 、 b_c 、 b_o 是输入门、遗忘门、更新记忆细胞、输出门的偏差; σ 是 Sigmoid 激活函数; $\tanh$ 是双曲正切激活函数。




图 4 LSTM 单元结构

Fig. 4 LSTM unit structure

2.2 卷积神经网络 (CNN)

CNN 以多个滤波器进行目标特征提取。通常由输入层、卷积层、激活函数层、池化层、全连接层和输出层组成^[19],其结构如图 5 所示。




图 5 典型 CNN 结构

Fig. 5 Typical CNN structure

图 5 中的输入层接收原始数据,卷积层通过卷积核提取特征,激活函数层引入非线性。卷积核提取特征是通过卷积运算来提取输入数据的特征,具体来说,给定输入矩阵(通常是图像)和卷积核(filter kernel),假设输入矩阵为 X ,卷积核为 K ,输出矩阵为 Y ,则卷积操作可表示为

$$Y(i,j) = \sum_{p=1}^P \sum_{q=1}^Q X(i+p-1,j+q-1) * K(p,q). \quad (6)$$

式中: $Y(i,j)$ 是输出矩阵 Y 中的元素,表示在位置 (i,j) 的值; $X(i+p-1,j+q-1)$ 是输入矩阵 X 中的元素,表示在位置 $(i+p-1,j+q-1)$ 处的值; $K(p,q)$ 是卷积核 K 中的元素,表示在位置 (p,q) 处的值; P 和 Q 分别是卷积核的高度和宽度;该过程是通过将卷积核在输入矩阵上滑动,并在每个位置上进行元素乘法累加得到的。

池化层用来降低维度,防止过拟合风险。全连接层学习全局信息,对经过卷积和池化的特征图进一步提取特征,并将其连接成一维向量。

2.3 支持向量机 (SVM)

SVM 采用监督学习方式对数据进行二元分类,其独特之处在于通过求解学习样本得到的最大边距超平面来确定决策边界。SVM 以最大化分类边界的间隔为目标,来构建最佳的决策超平面。同时通过将低维非线性不可分问题投射到高维空间转化为线性可分问题,寻找一个性能最优的决策面来完成数据分类,具体原理如图 6 所示。




图 6 SVM 原理图

Fig. 6 SVM schematic diagram

分类超平面表达式为

$$w\phi(x) + b = 0. \quad (7)$$

式中: w 为权值; b 为偏差。决策函数为

$$f(x) = \text{sign}[w\phi(x) + b]. \quad (8)$$

式中 $\text{sign}()$ 为符号函数。最优分类决策面可描述为:

$$\left. \begin{aligned} \min_{w,b} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i; \\ \text{s. t.} \quad & y_i(w\phi(x_i) + b) \geq 1 - \xi_i, i = 1, 2, 3, \dots, n; \\ & \xi_i \geq 0. \end{aligned} \right\} \quad (9)$$

由于直线无法完全区分所有样本,因此引入松弛变量 ξ_i 实现允许存在有限的误差,接受存在少数不满足约束条件的样本。应用拉格朗日乘子法将求最优决策面转变为对偶优化问题,即:

$$\left. \begin{aligned} \max_{\alpha} \quad & L_v = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j); \\ \text{s. t.} \quad & \sum_{i=1}^n \alpha_i y_i = 0, 0 \leq \alpha_i \leq C. \end{aligned} \right\} \quad (10)$$

式中 $K(x_i, x_j) = \Phi(x_i) \Phi(x_j)$ 称为核函数,主要完成数据从低维空间到高维空间的映射,核函数不同,所得支持向量机性能不同。

3 LSTM-CNN 和 BO-SVM 模型

3.1 LSTM-CNN 特征融合

GIS 内部绝缘缺陷产生的局部放电具有周期相关性,首先使用一维数据进行最简单的时域数据提取,其中采用 18 MHz 的特高频采样率和 90 kHz 的超声采样率,而后对这些数据进行绘制,将一维数据映射到二维图像中,进行图像特征值的提取。对于一维数据,本文使用的特征值提取方式为 LSTM;对

于二维数据,本文使用 CNN 特征值提取方式;最后将所有特征数据输入到 BO-SVM 中,实现绝缘缺陷分类识别。对于特高频数据,18 M = 18 000 000, 50 个周期,每个周期采集 $18\,000\,000/50 = 360\,000$ 个点。对于超声数据,90 K = 90 000, 50 个周期,每个周期采集 $90\,000/50 = 1\,800$ 个点。根据采集信号的频率和计算复杂度,且灰度图要满足完全反映原始信号的关键特征,通过大量实验最终分别选择特高频数据每 1 000 个点和超声数据每 5 个点进行归一化处理得到灰度图。将一维数据映射到二维图像,具体过程如图 7 所示。图 7 中首先对该组数据

进行平方,将处理后的 18 M 的数据划分为 18 000 组,而后将这每部分 1 000 个点进行求和,并对 18 000 个数据进行归一化处理。这样对数据进行处理,能够很好地屏蔽掉噪声信号的干扰问题,因为噪声问题是连续型信号,与外施电压并无关系。归一化处理导致一定程度的数据压缩,但通过实验验证,其能够既保证特征的有效保持,且充分发挥了 LSTM 和 CNN 的优势。本文将其每部分归一化处理,只是增大了其数值,并不改变其在混叠信号中的权值,本方法的优势在于不需要考虑其噪声问题,甚至不需要进行降噪处理。




图 7 一维信号到二维信号的转换

Fig. 7 Conversion of one-dimensional signals to two-dimensional signals

3.2 BO-SVM 分类

贝叶斯优化是一种广泛应用于调整模型超参数的方法,它是一项可以用于优化任何无法直接观察其内部机制的函数,也就是所谓的黑盒函数。本文使用贝叶斯优化 SVM 的 2 个超参数 γ 和 C 。核尺度 γ (Kernel Scale) 和框约束 C (Box Constraint) 是 SVM 中 2 个重要的超参数。核尺度 γ 的大小直接影响支持向量的数量,较大的 γ 导致较少的支持向量,而较小的 γ 导致较多的支持向量。框约束 C ,也称为惩罚系数,表示对误差的容忍度。较高的 C 值表示对误差容忍度较低,容易导致过拟合;而较低的 C 值表示对误差容忍度较高,容易导致欠拟合。因此,正确选择超参数是影响分类结果的关键因素。

本文构建 BO-SVM 模型的具体步骤如图 8 所

示。1) 初始化:随机选择超参数组合作为初始采样点,并使用十折交叉验证计算这些点的平均测试准确率。将这些初始采样点的超参数和对应的准确率作为初始代理模型的输入数据,形成采样点集 D 。2) 构建代理模型:使用高斯过程 (Gaussian Process) 建立代理模型估计超参数和测试准确率之间的关系。这个代理模型用于在超参数空间中预测未知点的性能。3) 采集函数选择下一个采样点:使用采集函数 (Acquisition Function) 在当前代理模型下选择下一个要评估的超参数。采集函数的目标是调整代理模型,使其更准确映射目标函数在超参数空间中的分布。4) 评估目标函数:使用选择的超参数进行 SVM 训练,并在验证集上评估后得到目标函数值 (平均测试准确率)。5) 更新代理模型:将新的超参

数和目标函数值添加到采样点集 D 中,并使用这些数据更新代理模型,以提高对超参数和准确率之间关系的估计。6) 迭代:重复步骤,直到达到设定的最大迭代次数停止条件。7) 输出结果:当算法停止迭代时,输出最优采样点和对应目标函数最优值,即 SVM 模型的最优超参数 C 和 γ 。




图8 BO-SVM流程图

Fig.8 BO-SVM flowchart

通过贝叶斯优化,可以自动调整 SVM 的关键超参数,以最大化 SVM 的损失函数。该过程中,本文将 SVM 的超参数视为贝叶斯优化的待优化参数。实验结果显示,在相同的数据集下,经过优化的 SVM 相比未经优化的 SVM,其分类准确率提高了 4.62%。

3.3 LSTM-CNN 融合 BO-SVM

本文采用的 GIS 内部绝缘缺陷识别模型流程如图 9 所示。首先使用 LSTM 对一维时序信号和 CNN 对一维时序信号到二维信号转换后的图像信号进行特征指纹的提取。而后将提取到的特征值在 CNN 的融合层进行融合。融合策略为在最后一个卷积层后添加一个或多个全连接层作为融合层,在这里将来自 CNN 和 LSTM 的输出向量拼接起来形成一个新的向量,然后作为 BO-SVM 分类层的输入。不同层级之间的权重按照 LSTM: CNN = 1 800: 2 880。




图9 绝缘故障诊断模型流程图

Fig.9 Flow chart of insulation fault diagnosis model

4 实验与分类对比分析

4.1 绝缘缺陷样本集获取

GIS 绝缘缺陷等比例缩小实验平台如图 10 所示,其由 50 Hz 单相升压变压器(最高输出电压可达 110 kV)、试验罐体和信号采集系统构成。为保证实验与现场单相 126 kV GIS 运行工况的一致性,试验时设置 48 kV 的工频电压。




图10 GIS局部放电检测平台

Fig.10 GIS partial discharge detection platform

为确保获得可靠的局部放电样本,本文在实验过程中多次改变缺陷位置,以模拟局部放电的随机性。本文以信号源中实时采集的局部放电信号作为输入样本,构建了源域数据作为输入样本,包括悬浮电位(Ⅰ类缺陷)、绝缘子表面污秽(Ⅱ类缺陷)、金属突出物(Ⅲ类缺陷)、绝缘子气隙(Ⅳ类缺陷)、自由金属颗粒(Ⅴ类缺陷)这五类典型缺陷。通过这样的实验设计,获取了五类典型缺陷超声和特高频数据各 500 组数据(训练集样本占比 70%、测试集样本占比 20%、验证集样本占比 10%),用于进行绝缘缺陷分类诊断。本实验的输入量主要由一维时序信号输入 LSTM 和二维图像信号输入 CNN,以下主要列举超声信号的各种绝缘缺陷时序数据和使用图 7 方式处理后的归一化后的结果数据。

图 11 为各种绝缘缺陷的时序数据,这种方式下的时序数据都与 50 Hz 有较强的相关性。




图 11 绝缘缺陷超声时序信号

Fig. 11 Insulation defect ultrasonic timing signal

使用图 7 方式处理后,不论系统误差还是随机误差,仅仅改变其大小,并不改变其权值,所以不会对输入信号产生干扰。除自由金属颗粒以外,其余都是固定缺陷,而自由金属颗粒缺陷属于非固定式绝缘缺陷。由于金属异物的特殊性,其作为一个可

以运动的绝缘缺陷模型,经常脱离 GIS 罐体表面,故会出现上述较为明显的非 50 Hz 状态。但是对于金属异物其发生局部放电的时刻依然为施加工频电压的正半周期,其发生击穿依然为施加工频电压的负半周期,只是并不会发生在每个工频信号阶段,因此本文认为仅仅是在时间尺度的基础上每整个工频周期发生了不确定性的两点分布变化(即发生或没有发生的随机性),但是并没有改变其本身的横向考虑的 50 Hz 相关性,仅仅是在某些整周期内没有发生该现象,因此基于 GIS 内部发生局部放电基本都是在正半周期,击穿都是发生在负半周期这一规律,不论发生何种形式的绝缘故障,都与 50 Hz 具有较强的相关性。

4.2 不同特征提取方法对比

图 12 为各种绝缘缺陷按照图 7 方式处理后的二维灰度图,由处理后的图像发现,在每个工频电压周期内,都会出现两个颜色较为明显的放电带,其在电压最大处会有较为明显的放电。




图 12 绝缘缺陷超声信号归一化处理灰度图

Fig. 12 Normalized grayscale image of insulation defect ultrasonic signal

将本文所提方法与传统方法进行对比,而传统方法为局部放电相位分布(phase resolved partial discharge, PRPD),其是一种用于分析局部放电信号的方法,它能够反映局部放电信号在工频周期内的相位分布情况^[20-21]。不同类型的绝缘缺陷会导致局部放电信号的相位分布存在差异。目前,现有方法主要基于对局放图谱进行特征提取和分析。CNN 能够捕捉到灰度处理后的 PD 信号中与缺陷类型相关的特征信息,从而帮助区分不同类型的绝缘缺陷。

本文使用图 7 产生序列放电信号的灰度图和 PRPD 灰度处理后的进行对比,同样使用图 9 的方式,其时序数据完全相同,都由 LSTM 进行处理,唯一改变的是使用 CNN 进行灰度处理的图像不同,从而进行结果的输出和对比。图 13 为各种绝缘缺陷产生的 PRPD 图进行灰度处理后的示例输入。




图 13 不同绝缘缺陷信号的 PRPD 灰度图

Fig. 13 PRPD grayscale images of different insulation defect signals

4.3 不同方式下识别结果对比

本文实验均采用 PyTorch 框架,在一台配备 NVIDIA RTX 4060 16 GB GPU、Intel i7 - 11700 CPU 和 64 GB RAM 的计算机上进行。首先,通过得到传统 PRPD 方式和图 7 方式生成 CNN 输入量的方式进行对比,使用同样的 LSTM-CNN 特征融合和 BO-SVM 进行对比,得到的结果如表 1 所示。

表 1 PRPD 与新方法下灰度图分类准确率

Table 1 Accuracy of grayscale image classification using PRPD and new methods

方法	训练集/%	测试集/%	验证集/%	分类时间/s
PRPD	100	92.4	93.1	2.91
新方法	100	97.3	97.5	1.48

由这两种方法下的对比结果可得,在任意数据集下,本文所提出的图 7 所产生的灰度图分类准确率都优于传统 PRPD 方法下分类的准确率。这主要是由于新方法下产生的数据集对图像的精度划分更细致,而且新方法下产生的灰度图速度相比较于产生 PRPD 图谱再转换为灰度图,其效率更高,而且此方法不依赖外部设备,可以使用采集时序信号的上位机进行该方法的处理,便携性、效率、精度更好。

为了验证本文提出的基于 LSTM-CNN 特征融合和 BO-SVM 对 GIS 绝缘故障识别的先进性,本文选择与以下几个模型进行对比:LSTM-CNN 和 SVM、LSTM 和 BO-SVM、CNN 和 BO-SVM,对比结果如表 2 和图 14 所示。LSTM-CNN-BO-SVM 处理一个完整的绝缘缺陷样本平均耗时约为 3.5 s,而采用传统 PRPD 方法的类似流程平均耗时约为 8 s。这表明新方法在整个故障诊断过程中能够提供更快的速度,效率提升了约 1.29 倍。

表 2 诊断模型分类准确率对比

Table 2 Comparison of classification accuracy of diagnostic models

方法	训练集/%	测试集/%	验证集/%	识别时间/s
LSTM-CNN-SVM	100	94.8	93.9	2.85
LSTM-BO-SVM	100	95.5	95.9	2.78
CNN-BO-SVM	100	94.9	95.2	2.82
LSTM-CNN-BO-SVM	100	97.3	97.5	2.88




图 14 不同 SVM 方法的绝缘缺陷分类图

Fig. 14 Classification diagrams of insulation defects using different SVM methods

通过分析图 14 可以发现,采用贝叶斯优化的 SVM 分类更加准确。这是因为 SVM 在使用的过程中,超参数对其结果影响很大,通过贝叶斯优化,可以自动选择合适的超参数。在贝叶斯优化过程中,

使用 SVM 损失函数作为目标函数,将 SVM 的超参数设置为贝叶斯优化的优化参数,从而得到 SVM 最优超参数。图 15 为贝叶斯优化流程图,描绘了在调整目标函数参数“核尺度 (Kernel Scale)”及“框约束 (Box Constraint)”的不同数值配置下,目标函数值随之变动的情形。呈现了贝叶斯优化算法在搜索最优解过程中对这两个关键参数空间的求解,通过连续迭代,计算出在多维度参数空间中在全局优化问题上的结果。图 16 为贝叶斯优化的结果,可见随着函数计算次数的增加,目标函数值越来越小(本实验中优化的目标为 10 折交叉验证的损失函数)。试验结果表明,在相同的数据集下,优化后的 SVM 比未经优化的 SVM 分类准确率更高。




图 15 贝叶斯优化目标函数过程

Fig. 15 Bayesian optimization objective function process





图 16 SVM 迭代次数与目标函数关系

Fig. 16 Relationship between SVM iteration times and objective function


混淆矩阵能够提供对模型性能的清晰分析,特别是在各种故障类型错误分类方面,因此本文引入混淆矩阵来评估各种模型准确性。在对测试集样本进行模型训练并得到预测标签后,通过混淆矩阵,本文可以直观地了解模型在不同故障类型上的分类准确性。混淆矩阵的横轴表示预测标签,而纵轴表示测试集样本的真实标签。为确认 LSTM-CNN 特征

融合 BO-SVM 模型的可靠性,本文将其与其他模型进行比较,各模型识别率混淆矩阵如图 17 所示。


通过比较混淆矩阵图 17(a)、图 17(b),表明经过采用 BO 进行优化的 SVM 相比未经优化的 SVM 表现出更高的分类精度,验证了在进行 SVM 分类之前应用 BO 进行优化的有效性。通过引入 BO 优化可以显著提升 SVM 模型的性能,使其在分类任务中取得更为准确的结果。




(a) LSTM-CNN和BO-SVM模型混淆矩阵



(b) LSTM-CNN和SVM模型混淆矩阵



(c) LSTM和BO-SVM模型混淆矩阵



(d) CNN和BO-SVM模型混淆矩阵

图 17 不同方法的混淆矩阵结果
Fig. 17 Confusion matrix results for different methods

通过比较混淆矩阵图 17(c)、图 17(d),表明在使用同样的 BO-SVM 分类器的场景下,通过使用图 7—维信号到二维信号的转换方式,在处理除自由金属颗粒绝缘缺陷时,能够较为显著的提高分类能力,但是对于自由金属颗粒的缺陷识别能力有所降低,主要原因是,使用的一维信号到二维信号的转换方式是高度契合工频电压周期特征的,悬浮电位、绝缘子表面污秽、金属突出物、绝缘子气隙 4 种绝缘缺陷都是固定位置的局部放电方式。一旦带电的自由微粒在各种因素作用下开始移动,它们很有可能会运动到初始电场强度已经相当大的区域,此时,数倍的电场畸变便有可能使局部场强值超过 SF_6 气体的击穿场强或绝缘子等的闪络场强,引起局部放电。电荷积聚及电子运动的形式是局部放电电场能的积累与释放,但是金属异物一旦起跳后,其电荷量即保持不变。自由金属颗粒再次与极板碰撞时,电压并不一定处于正弦周期的最大值,因此其反弹时所带电荷量也有可能小于最初起跳升空时的带电荷量。因此金属异物的放电方式具有很小的周期相关性,其主要影响因素为自由微粒的形态和材质以及其在 GIS 罐体中所处的位置,因此引入二维的图像信号可能会对自由金属颗粒的故障分类产生一定的干扰。

通过比较混淆矩阵图 17(a)、图 17(c) 和图 17(d),发现采用 LSTM-CNN 特征融合和 BO-SVM 相较于单一维度特征提取的方式具有更高的分类准确率。因此证明本文所采用融合策略进行

GIS 绝缘故障诊断的优越性,结果表明结合多个数据源进行多特征融合可以提升模型性能,从而更准确地进行缺陷分类。对于周期相关性较强的采用一维时序信号到二维信号的转换方式能够较好地提升识别的准确性。对于周期性不强的自由金属微粒缺陷,将其剔除 CNN 融合层,从而能够缩小特征维度,降低运算时长的同时提高模型的识别准确度。

5 结 论

本文提出基于超声和特高频的融合数据采集,使用 LSTM-CNN 特征融合和 BO-SVM 对 GIS 设备内部绝缘缺陷进行分类,并与其他 SVM 方法通过模型分类图和混淆矩阵进行对比。本文主要结论如下:

1) 采用 LSTM 对一维时序信号和 CNN 对二维卷积神经网络的融合方式,以提取数据的特征值。所使用的一维时序信号到二维信号的转换能更好地突出局部放电的周期相应特性,在针对固定位置的局部放电方式,悬浮电位、绝缘子表面污秽、金属突出物、绝缘子气隙 4 种绝缘缺陷时,能够提取到一维信号无法捕捉的指纹特征,最终能较好地提升识别准确度,且新方法比传统 PRPD 图谱法识别速度提升约 1 倍。对于周期性不强的自由金属微粒绝缘缺陷,采用剔除 CNN 融合层,从而在缩小特征维度和降低运算时长的同时提高了模型的识别准确度。

2) 通过将 2 种特征值在 CNN 的融合层进行整合,形成一个融合后的特征表示。最终,本文将经过融合的特征值输入到基于 BO-SVM 的分类层,在采用贝叶斯优化后的分类器中,能够较好地提升模型的绝缘故障分类准确度。本文所提融合模型相比较于开发新的训练模型,不仅减轻了开发难度,同时也为目前 GIS 绝缘缺陷故障识别提供了有效途径。

3) 与其他结合本文所提一维信号到二维信号转换方法的 SVM 方法相比,本文所提的融合模型在准确性、鲁棒性等方面都取得了显著的进展,在自由金属颗粒缺陷识别准确率提升约 4%。本文所提新方法较传统 SVM 方法在识别时间上提升了 1.29 倍。对于处理周期相关性强的悬浮电位缺陷、绝缘子表面污秽放电、金属突出物缺陷、绝缘子气隙缺陷和周期相关性不强的自由金属颗粒缺陷准确率都有显著的提升,说明本文所提融合模型在复杂环境下基于超声和特高频信号实现 GIS 绝缘故障识别具有广阔的应用前景。

参 考 文 献:

- [1] 李庆民,魏来,薛乃凡,等. 交直流 GIS/GIL 微纳粉尘可视化探测技术研究进展[J]. 高电压技术, 2023, 49(9): 3607.
LI Qingmin, WEI Lai, XUE Naifan, et al. Research advances in visualization detection technology of micron-nano dust in AC and DC GIS/GIL[J]. High Voltage Engineering, 2023, 49(9): 3607.
- [2] 胡新文,李晓昂,王舒啸,等. 冲击振动激励下 GIS 内自由金属微粒运动及其诱发间隙击穿特性[J]. 高电压技术, 2024, 50(1): 339.
HU Xinwen, LI Xiaolang, WANG Shuxiao, et al. Free metal particles movement and its induced gap breakdown characteristics in GIS under impact vibration[J]. High Voltage Engineering, 2024, 50(1): 339.
- [3] 段大卫,马宏忠,杨启帆,等. 粘滞阻力下交流 GIL 中线形颗粒运动行为研究[J]. 电机与控制学报, 2021, 25(11): 83.
DUAN Dawei, MA Hongzhong, YANG Qifan, et al. Motion analysis of linear particle in AC GIL considering viscous resistance[J]. Electric Machines and Control, 2021, 25(11): 83.
- [4] 任明,余家赫,王凯,等. 气体绝缘微粒放电多光谱脉冲检测及特性分析[J]. 中国电机工程学报, 2022, 42(S1): 295.
REN Ming, YU Jiahe, WANG Kai, et al. Multispectral pulse detection and characteristic analysis of gas insulated particle discharge[J]. Proceedings of the CSEE, 2022, 42(S1): 295.
- [5] 张昭宇,胡一丹,宋颜峰,等. 电力设备机械振动-超声波融合检测传感器研制及应用[J]. 中国电机工程学报, 2023, 43(14): 5713.
ZHANG Zhaoyu, HU Yidan, SONG Yanfeng, et al. Development and application of mechanical vibration-ultrasound combined sensor for power equipment[J]. Proceedings of the CSEE, 2023, 43(14): 5713.
- [6] 王靖瑞,李庆民,刘衡,等. 纳米复合涂层对微米级金属粉尘吸附行为的抑制作用[J]. 电工技术学报, 2022, 37(12): 3172.
WANG Jingrui, LI Qingmin, LIU Heng, et al. Suppression effect of nanocomposite coating on the adsorption behavior of micron-scale metal dust[J]. Transactions of China Electrotechnical Society, 2022, 37(12): 3172.
- [7] 池明赫,夏若淳,罗青林,等. 油纸绝缘典型缺陷局放特性及缺陷类型识别[J]. 电机与控制学报, 2022, 26(2): 121.
CHI Minghe, XIA Ruochun, LUO Qinglin, et al. Partial discharge characteristics and defect type identification of typical defects in oil-pressboard insulation[J]. Electric Machines and Control, 2022, 26(2): 121.
- [8] WANG Y, YAN J, YANG Z, et al. GAN and CNN for imbalanced partial discharge pattern recognition in GIS[J]. High Voltage, 2022, 7(3): 452.
- [9] DAI D, WANG X, LONG J, et al. Feature extraction of GIS partial discharge signal based on S-transform and singular value decomposition[J]. IET Science, Measurement & Technology,

- 2017, 11(2): 186.
- [10] LI X, WANG X, XIE D, et al. Time-frequency analysis of PD-induced UHF signal in GIS and feature extraction using invariant moments[J]. IET Science, Measurement & Technology, 2018, 12(2): 169.
- [11] WANG Y, YAN J, YANG Z, et al. GIS partial discharge pattern recognition via lightweight convolutional neural network in the ubiquitous power internet of things context[J]. IET Science, Measurement & Technology, 2020, 14(8): 864.
- [12] YANG H, ZHANG J, CHEN L, et al. Fault diagnosis of reciprocating compressor based on convolutional neural networks with multisource raw vibration signals[J]. Mathematical Problems in Engineering, 2019(1): 6921975.
- [13] 冯英, 李旭, 钟尧, 等. 基于多层融合振动数据分析的 GIS 设备机械缺陷诊断方法研究[J]. 中国电机工程学报, 2024, 44(14): 5797.
- FENG Ying, LI Xu, ZHONG Yao, et al. Research on the GIS mechanical defects diagnosis method based on multi-layer fusion vibration data analysis[J]. Proceedings of the CSEE, 2024, 44(14): 5797.
- [14] 王艳新, 闫静, 王建华, 等. 基于域对抗迁移卷积神经网络的小样本 GIS 绝缘缺陷智能诊断方法[J]. 电工技术学报, 2022, 37(9): 2150.
- WANG Yanxin, YAN Jing, WANG Jianhua, et al. Few-shot partial discharge diagnosis for gas-insulated switchgear using a novel multi-level second-order attention siamese network[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2150.
- [15] 黄韬, 郝艳捧, 肖佳朋, 等. 10 kV XLPE 电缆终端典型安装缺陷的工频局部放电特征对比研究[J]. 电网技术, 2022, 46(6): 2420.
- HUANG Tao, HAO Yanpeng, XIAO Jiapeng, et al. Comparative study on partial discharge characteristics of typical installation defects in 10 kV XLPE cable terminals under power frequency[J]. Power System Technology, 2022, 46(6): 2420.
- [16] 钱庆林, 孙炜昊, 王真, 等. 基于非线性尺度空间与极坐标分布熵的 GIS 局放特征提取方法[J]. 电网技术, 2024, 48(8): 3525.
- QIAN Qinglin, SUN Weihao, WANG Zhen, et al. Feature extraction method for partial discharge in GIS based on KAZE and distribution entropy in polar coordinates[J]. Power System Technology, 2024, 48(8): 3525.
- [17] 吴闽, 蒋伟, 罗颖婷, 等. 基于改进 SSD 的 GIS 多源局放模式识别[J]. 高电压技术, 2023, 49(2): 812.
- WU Min, JIANG Wei, LUO Yingting, et al. Multi-source partial discharge pattern recognition in GIS based on improved SSD[J]. High Voltage Engineering, 2023, 49(2): 812.
- [18] 马宏忠, 肖雨松, 颜锦, 等. 基于多特征提取和麻雀搜索算法优化 XGBoost 的变压器绕组松动诊断方法[J]. 电机与控制学报, 2024, 28(6): 87.
- MA Hongzhong, XIAO Yusong, YAN Jin, et al. Transformer winding looseness diagnosis method based on multiple feature extraction and sparrow search algorithm optimized XGBoost[J]. Electric Machines and Control, 2024, 28(6): 87.
- [19] 万晓琪, 宋辉, 罗林根, 等. 卷积神经网络在局部放电图像模式识别中的应用[J]. 电网技术, 2019, 43(6): 2219.
- WAN Xiaoqi, SONG Hui, LUO Lingen, et al. Application of convolutional neural networks in pattern recognition of partial discharge image[J]. Power System Technology, 2019, 43(6): 2219.
- [20] 董冰冰, 高常胜, 许渊, 等. 基于修正时频聚类分界的 GIS 设备特高频偶发局放识别算法[J]. 高电压技术, 2023, 49(11): 4736.
- DONG Bingbing, GAO Changsheng, XU Yuan, et al. Identification algorithm of UHF occasional partial discharge of GIS equipment based on modified time-frequency clustering boundary[J]. High Voltage Engineering, 2023, 49(11): 4736.
- [21] 许辰航, 陈继明, 刘伟楠, 等. 基于深度残差网络的 GIS 局部放电 PRPD 谱图模式识别[J]. 高电压技术, 2022, 48(3): 1113.
- XU Chenhang, CHEN Jiming, LIU Weinan, et al. Pattern recognition of partial discharge PRPD spectrum in GIS based on deep residual network[J]. High Voltage Engineering, 2022, 48(3): 1113.

(编辑:邱赫男)