

基于改进 FCN 双路径特征融合的局部放电图谱识别

金玉^{1,2} 袁和金^{1,2}

(1. 华北电力大学计算机系 保定 071003; 2. 复杂能源系统智能计算教育部工程研究中心 保定 071003)

摘要: 针对电力设备局部放电图谱的识别问题,提出一种改进交叉熵损失函数的双路径全卷积神经网络模型。使用局放图谱作为模型输入,采用双路径的方式,两路使用不同大小卷积核分别提取图谱较深层和较浅层特征,然后进行特征融合。使用卷积层代替全连接层,更多保留局放特征间的空间关联性。改进的交叉熵损失函数可以使模型更适用于数据集样本不均衡的情况。实验结果表明,改进 FCN 双路径特征融合识别方法准确率达到 99.31%,可以准确识别局放图谱,且模型参数量更小。

关键词: 局部放电;卷积神经网络;特征融合;交叉熵损失函数

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Partial discharge pattern recognition based on improved FCN dual path feature fusion

Jin Yu^{1,2} Yuan Hejin^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;

2. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, Baoding 071003, China)

Abstract: A fully convolutional dual-path neural network model with improved cross-entropy loss function is proposed to solve the problem of identifying partial discharge maps of electrical equipment. Using the partial discharge map as the model input, the deep and shallow features of the map are extracted by two channels using different size convolution kernels, and then performing feature fusion. The convolutional layer is used instead of the fully connection layer to preserve more spatial correlation between PD features. The improved cross-entropy loss function can make the model more suitable for the situation of imbalanced datasets. The experimental results show that the accuracy of the improved FCN dual-path feature fusion recognition method reaches 99.31%, which can accurately identify the partial discharge map, and the amount of model parameters is smaller.

Keywords: partial discharge; convolutional neural network; feature fusion; cross entropy loss function

0 引言

电力设备在长期运行过程中,难免受周围空气、环境等的影响从而产生一些缺陷,进而导致局部放电现象的产生。电力设备的局部放电现象会使其绝缘材料老化,甚至引发高压电力设备的绝缘击穿^[1],从而给电力设备的安全运行带来重大影响。因此,对电力设备的局部放电现象进行监控、识别,对电网安全具有重要意义。

局部放电主要包括悬浮电极放电、内部缺陷放电、沿面放电,以及自由金属颗粒放电 4 种典型缺陷^[2]。常用的局部放电模式识别方法主要包括两种:对原始局放信号或局放图谱进行特征提取,然后将局放特征输入分类器中进行模式识别;使用深度学习方法自动提取特征并进行分类。

文献[3]提取局放信号波形特征参数数据库,针对超声波信号的单次脉冲进行特征参数提取。文献[4]利用时频分析和小波分解,提取信号的时频特征和小波系数特征,通过线性判别算法(linear discriminant analysis, LDA)对提取的特征向量进行降维处理,从而构建特征数据库。特征提取加模式识别的这类方法,在特征提取的过程中,其特征、处理方法等的选择对经验性依赖大,并且需要耗费较多时间,很难在保证准确率的同时兼顾其泛化能力。

近年来,深度学习被广泛应用于各领域,其优势之一就在于其可以自动进行特征提取并进行分类。卷积神经网络就是典型的深度学习模型,随着卷积神经网络的不断发展,已有学者将其应用于局放分析,效果明显优于传统的单独进行特征提取的识别方法^[5-6]。文献[7]使用改进激活函数

的 MobileNet-V2 预训练模型,在局放图谱上进行迁移学习。文献[8]使用卷积神经网络(convolutional neural networks,CNN)和深度置信网络(deep belief network,DBN)融合而成的复合神经网络模型进行局放模式分类。这种直接使用卷积神经网络进行局放模式识别的方法,往往会忽略局部放电图谱变化趋势的特征,从而丢失部分有效特征。

基于此,本文提出了一种基于全卷积神经网络的双路径特征融合 PRPD 图谱模式识别方法。针对局放图谱变化趋势的特征,一路使用较大卷积核获得更大感受野,提取图像浅层特征;一路使用较小卷积核获得更小感受野,提取图像深层特征,然后将两路特征融合,输入到转置卷积层中进行分类,可以保留图像更多有效特征,提升识别准确率。另外,为克服数据集中个别样本训练困难的问题,改进交叉熵损失函数,进一步提升了识别准确率,使模型更适用于实际现场采集局放图谱的识别。

1 RPPD 局放图谱

目前,现场采集的局部放电数据多以图谱形式存储,称为局部放电图谱。当局放检测设备在一个设定周期内检测到放电脉冲数大于正常数,且非干扰信号时,会将该周期内将每个带有相位标识的局部放电脉冲信号按照相位显示并保存下来,从而生成局放图谱。局部放电图谱主要有脉冲信号二维分布图(phase resolved partial discharge pattern, PRPD)、脉冲信号三维分布图(phase resolved pluse sequence, PRPS)两类^[9]。局部放电图谱如图 1 所示,左侧为 PRPD 图谱, X 轴表示相位, Y 轴表示脉冲信号的幅值^[10]。右侧为 PRPS 图谱, X 轴表示相位, Y 轴表示周期, Z 轴表示脉冲信号幅值。




图 1 局放图谱示例

通过对广东省某电力公司 110 kV 变电站进行带电检测,获取实际运行环境下 4 种典型缺陷放电 PRPD 图谱共 600 张,其中包括悬浮电极放电、内部缺陷放电、沿面放电,以及自由金属颗粒放电各 150 张,4 种典型缺陷放电 PRPD 图谱如图 2 所示。

由局放缺陷的 PRPD 图谱可以看出,不同缺陷类型放电图谱在放电幅值区间,以及正半周期和负半周期上的分布有明显差异且各有特征。因此可以使用经验法可以判断其放电类型,但由于人工进行图谱分类耗时巨大,亟需研究高效、高准确率自动识别方法。

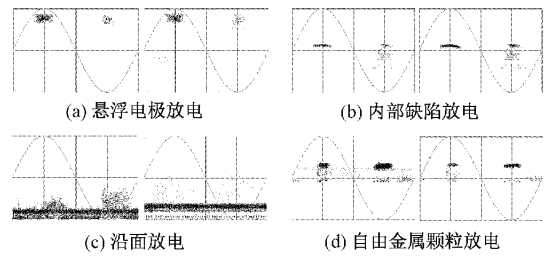


图 2 4 种典型局放缺陷 PRPD 图谱

2 基于 FCN 双路径特征融合的局放模式识别

2.1 全卷积神经网络

卷积神经网络(convolutional neural network,CNN)模型架构如图 3 所示。




图 3 传统卷积神经网络结构

卷积神经网络的核心是卷积层,用来提取图像特征^[11]。池化层的作用是在保留数据特征的同时,进行降采样,可以极大降低网络参数量^[12]。全连接层是将前面提取的特征组合成一个值,可以减少特征的位置对于分类结果的影响。

全卷积神经网络(fully convolutional network, FCN)^[13]是卷积神经网络的变形之一,其特点在于使用卷积层替代全连接层。PRPD 图谱表示的是脉冲与相位的分布,其分布有空间上的关联^[14],使用全连接层会破坏这种空间上的关联性,导致模型训练效果变差。因此,将全连接层替换为转置卷积层,将卷积层局部连接操作的局部替换为最大的局部,即全局,以代替全连接层。

2.2 双路径特征融合

局部放电 PRPD 图谱是由多个点组成的散点图,在提取特征时,既要关注局部范围内点的分布特征,又要关注其整体趋势的异同。传统卷积神经网络通过卷积操作对图像进行下采样,逐渐提取更高维的特征^[15],因此往往会忽略图像的浅层特征。由此,本文提出了一种双路径特征融合模型结构。网络模型采用双路径的结构,两路均包括 3 层卷积结构,分别使用 3×3 大小的卷积核获得更大感受野,提取图像浅层特征;使用 2×2 大小的卷积核获得更小感受野,提取图像深层特征。然后将两路进行通道维度上的特征融合,更多保留图像的局部特征,以及表示整体变化趋势的特征。

模型中每个卷积结构均包含 4 层操作,包括卷积层、归一化层、使用 ReLU 函数的激活层,以及自适应平均池化层。在卷积层后中加入归一化层,可以保证每次训练完的

数据都在正态分布上^[16],避免梯度消失问题,同时加快模型的收敛速度。

为避免全连接层破坏特征间空间关联性的问题,本文设计的模型将最后的全连接层替换为卷积核大小为 3×3 ,步长为 1 的转置卷积层,其输入是上一层的输出通道数,输出是分类类别数量。在最后的转置卷积层前,加 Dropout

层,随机删除网络中隐藏层的部分神经元,并保存其当前状态,在剩余神经元上继续训练操作,反向更新参数,此时加回被删除的神经元,继续训练操作,不断循环,以此来防止过拟合。同时在数据集小的情况下,可以通过 Dropout 的增加稀疏性,来增加特征的区分度^[17]。FCN 双路径特征融合模型结构如图 4 所示。




图 4 FCN 双路径特征融合网络结构图

2.3 损失函数的改进

损失函数是评估模型性能好坏的重要因素之一,使用损失函数的值反向传播更新网络参数,来起到优化网络模型的目的。通常损失值越小,代表模型性能越好^[18]。

交叉熵损失函数(cross entropy loss)常用于解决分类问题。交叉熵描述预测值和真实值之间的距离,距离越小,说明预测越准确。交叉熵损失函数的公式如式(1)所示:

$$CE_{Loss} = \begin{cases} -\log(p), & y = 1 \\ -\log(1-p), & \text{其他} \end{cases} \quad (1)$$

其中, p 是预测为正确类别的概率,表示样本分类的困难程度,如果 p 的数值较大,说明是易分类的简单样本,较小则是困难样本。如果比较难以分类的样本数量少,相对容易分类的样本数量多,易分类样本就会占总的损失值的大部分,使得难分样本更加难分^[19]。为解决样本分布不均衡导致的训练困难问题,通常做法是给不同类别的样本前分别加上权重因子 α_i , 其大小由样本数量决定,样本数量多的类别设置较高的权重因子,样本数量多的类别反之。

带权重的交叉熵损失函数可以解决样本数量不均衡的问题,但没有解决样本难易程度与数量不匹配的问题,如难分样本数量较少,易分样本数量较多等问题。所以除了在交叉熵损失函数的基础上加类别权重因子外,再加上调节样本难易的权重因子 γ , 进一步改进的交叉熵损失函数公式如式(2)所示:

$$CE_{Loss_Y} = \begin{cases} -\frac{\alpha_i}{p^\gamma} \log(p), & y = 1 \\ -\frac{(1-\alpha_i)}{(1-p)^\gamma} \log(1-p), & y = 0 \end{cases} \quad (2)$$

其中, $(1-p)^\gamma$ 可称为调制系数, $1-p$ 为调制因子,当样本易分时, p 数值较大,调制因子较小,此时增大 γ , 可进一步减小易分样本占损失值的比例,从而使模型更多关注难分样本,更有利于提高模型训练的准确性。

2.4 局放模式识别

基于 FCN 双路径特征融合的局放模式识别流程图 5 所示。原始数据集为 4 种典型缺陷放电 PRPD 图谱共 600 张,将数据集进行预处理后分为训练集和测试集。将训练集输入基于 FCN 双路径特征融合的网络模型进行训练,使用随机梯度下降算法,采用改进的交叉熵损失函数计算误差并反向传播,对网络中的超参数不断进行调整优化。当误差曲线收敛且误差值基本不变时停止训练并保存模型。使用测试集对网络模型的识别性能进行评估。

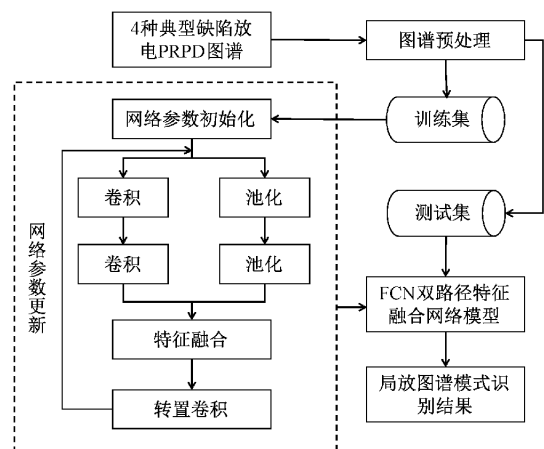


图 5 基于改进 FCN 双路径特征融合的局部放电模式识别流程

3 实验结果与分析

3.1 图谱预处理

由于现场采集的局放图谱中包含背景网格、参考正弦波等其他信息,直接输入神经网络模型中会对特征提取造成一定的影响。以及作为网络模型的输入需要对图谱进行规范化处理。因此,首先要对图谱进行预处理操作。本文图谱的预处理主要包括灰度化、二值化,以及归一化 3 个过程。其中归一化操作又包括正态分布归一化和尺寸归一化。对图谱的处理流程如图 6 所示。




图 6 图谱预处理流程

不同于日常生活中常用的 RGB 颜色空间, YUV 颜色空间是非线性颜色空间,其 Y 分量的含义是点的亮度等级,即灰阶值。U、V 分量的含义是色度。图像的灰度值可以由 YUV 颜色空间中的灰阶值分量 Y 与 RGB 中 3 个分量的对应关系来表示,公式如式(3)所示:

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (3)$$

为进一步减少数据量,突出图像特征,图谱灰度化后进行二值化处理。根据本数据集特性,不断进行尝试,发现将二值化阈值设置为 187 时效果最好。再将二值化后的图像进行色彩反相,以突出特征,淡化背景。选择合理的阈值,可以在二值化的同时进行背景去噪,如将 PRPD 图谱中的网格和正弦波去掉。

在数据预处理时对数据集进行归一化,可加快模型的收敛速度。归一化操作的公式为 $x = (x - \text{mean}) / \text{std}$,即用同一纬度的数据减去这一维度的平均值再除以标准差,归一化后的数据符合标准正态分布。根据图谱的实际像素大小,将图谱大小统一为 72×72 。图 7 为进行预处理后的 4 种局放典型缺陷的 PRPD 图谱。




图 7 预处理后的典型局放缺陷 PRPD 图谱

3.2 网络训练

随机梯度下降算法(stochastic gradient descent, SGD)是随机挑选某一分量的梯度方向进行收敛,给其加一个动

量,可以加大在该梯度的训练惯性。设置不同参数动量的模型收敛速度对比如图 8 所示,通过不断尝试,发现随机梯度下降算法的动量参数设置为 0.9 时,模型收敛速度最快,且准确率最高。




图 8 优化器设置不同动量网络收敛速度的对比

当模型训练中配置的学习率较低时,需要迭代次数增多,模型训练速度慢;当学习率较高时,模型会比较难收敛。在使用 SGD 进行训练时,在接近损失值极值时,缩减随机梯度下降步长,可以帮助模型更快的收敛。因此,本文动态设置学习率,经过多次尝试后,发现将学习率初始值设为 0.001,每 5 次迭代下降 50%,可以获得最好的模型训练效果。

3.3 结果与分析

本文使用基于 Python 的 PyTorch 框架编写网络训练及测试模型。实验所用的 GPU 型号为 NVIDIA GeForce RTX 2080 Ti,软件环境为 Windows 10,64 位操作系统及 PyCharm 集成开发环境。

模型训练采用随机梯度下降算法,为解决现场采集的局放图谱数据集有个别样本训练困难的情况,提出了改进的交叉熵损失函数作为该模型的损失函数,根据误差函数对网络中的超参数不断进行调整优化。

为了比较起见,这里将本文算法与未改进损失函数的双路径全卷积神经网络(双路径 FCN)、改进损失函数的双路径卷积神经网络(改进损失函数+双路径 CNN),以及只有 3 层卷积的传统卷积神经网络分别进行实验,结果如表 1 所示,不同算法的收敛速度如图 9 所示,不同算法的损失值变化对比如图 10 所示。可以看到,进行双路径特征融合或改进损失函数,均能提升模型的准确率,在改进损失函数的基础上进行双路径特征融合的全卷积神经网络模型收敛速度更快,识别准确率更高。

表 1 不同算法识别准确率

算法	准确率/%	参数量/M
本文算法	99.31	0.04
双路径 FCN	98.61	0.04
改进损失函数+双路径 CNN	97.26	0.36
传统 3 层 CNN	96.29	0.09




图 9 不同算法对收敛速度的影响




图 10 不同算法的损失值变化

4 结 论

本文提出了一种双路径特征融合的全卷积神经网络模型,将其应用于电力设备局部放电 PRPD 图谱的模式识别中。双路径可以提取图像的深层、浅层特征,以保留更多有效特征。通过改进交叉熵损失函数,使模型更适用于样本不均衡的情况。实验结果表明,使用自制的浅层神经网络,在提升了识别准确率的前提下,减少了模型参数量,提高了识别速度。其轻量、高效的特点使该模型能够方便的嵌入移动设备,更高效地应用于实际现场使用中。

参考文献

- [1] 唐志国,曹智,何宁辉. 卷积神经网络迁移学习在局部放电类型诊断中的应用[J]. 高压电器, 2022, 58(4): 158-164.
- [2] 郑祥,管鹏,田伟. 基于超声波局部放电信号的开关柜绝缘缺陷类型识别[J]. 电子测量技术, 2020, 348(16): 124-127.
- [3] 韩世杰,吕泽钦,隋浩冉,等. 基于 EFPI 传感器的 GIS 局部放电模式识别研究[J]. 电力工程技术, 2022, 41(1): 149-155.
- [4] 王卓,朱宁宁,郑祥. 基于 LDA 和 RBF 神经网络的开关柜局部放电模式识别方法研究[J]. 电子测量技术, 2021, 370(14): 148-152.
- [5] 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): 2219-2226.
- [6] 范路,陆云才,陶风波,等. 人工智能在局部放电检测中的应用(二):模式识别与状态评估[J]. 绝缘材料, 2021, 54(7): 10-24.
- [7] 程江洲,温静怡,鲍刚,等. 基于 T-MobileNet-L 模型的 GIS 局部放电模式识别研究[J]. 电子测量技术, 2021, 376(20): 22-28.
- [8] 袁文海,刘彪,徐浩,等. 基于复合神经网络的 GIS 局放故障类型识别[J]. 电力科学与技术学报, 2021, 36(4): 157-164.
- [9] FENG C G. Identification of partial discharge defects in gas-insulated switchgears by using a deep learning method[J]. IEEE Access, 2020, 8: 163894-163902.
- [10] 刘维功,王昊展,时振堂,等. 基于改进 XGBoost 算法的 XLPE 电缆局部放电模式识别研究[J]. 电测与仪表, 2022, 59(4): 98-106.
- [11] 张小丹,陈媛媛. 基于卷积神经网络的近红外光谱模型迁移研究[J]. 国外电子测量技术, 2021, 320(7): 100-104.
- [12] GANGULY B, CHAUDHURI S, BISWAS S, et al. Wavelet kernel-based convolutional neural network for localization of partial discharge sources within a power apparatus [J]. IEEE Transactions on Industrial Informatics, 2020, 17(3): 1831-1841.
- [13] 张鑫,姚庆安,赵健,等. 全卷积神经网络图像语义分割方法综述[J]. 计算机工程与应用, 2022, 58(8): 45-57.
- [14] LI G, WANG X, LI X, et al. Partial discharge recognition with a multi-resolution convolutional neural network[J]. Sensors, 2018, 18(10): 3512.
- [15] LIU T, YAN J, WANG Y, et al. GIS partial discharge pattern recognition based on a novel convolutional neural networks and long short-term memory[J]. Entropy, 2021, 23(6): 774.
- [16] TUYET-DOAN V N, PHO H A, LEE B, et al. Deep ensemble model for unknown partial discharge diagnosis in gas-insulated switchgears using convolutional neural networks [J]. IEEE Access, 2021, 9: 80524-80534.
- [17] DO T D, TUYET-DOAN V N, CHO Y S, et al. Convolutional-neural-network-based partial discharge diagnosis for power transformer using UHF sensor[J]. IEEE Access, 2020, 8: 207377-207388.
- [18] 刘春霞,高强,潘理虎,等. 融合交叉熵损失的 3DCNN 探水作业动作识别[J]. 计算机工程与设计, 2022, 43(4): 1160-1165.
- [19] 刘艳菊,王秋霖,赵开峰,等. 基于卷积神经网络的热轧钢条表面实时缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 211-219.

作者简介

金玉(通信作者),硕士研究生,主要研究方向为图像处理等。

E-mail:243923047@qq.com

袁和金,博士,副教授,硕士生导师,主要研究方向为模式识别和计算机视觉、图形与图像处理。

E-mail:yhj_1977@163.com