

基于 PCP 和改进 CNN 的变压器内外故障诊断方法研究

何龙, 朱咏明, 马金财, 刘荣

(国网新疆电力有限公司昌吉供电公司, 新疆 昌吉 831100)

摘要: 为了有效防止变压器差动继电器在非故障瞬态情况下的误动,提出了一种区分变压器内部、外部故障及其暂态过程的快速辨识方法。首先,针对工程现场监测数据可能包含噪声的问题,提出一种利用平行坐标图(PCP)对三相差动时间序列图像化的方法,将三相时间序列可视化,容纳了故障所有信息的同时保障了信号的抗噪性;其次,对卷积神经网络(CNN)加以改进:在特征提取部分增加 ECA 注意力机制模块,再利用优化后的多核支持向量机对 CNN 自带 Softmax 分类器进行改进,增强 CNN 对各类故障场景分类的适用性,并与实现变压器内外故障的诊断与辨识;最后,搭建变压器内部和外部故障仿真模型,获取绕组匝间故障、接线故障以及励磁涌流、电流互感器(CT)饱和铁磁谐振等故障时差动保护监测数据,据此构建图像化故障样本集,对论文所提方法进行验证,并与同类算法进行对比,证明所提方法的优越性。

关键词: 变压器故障; 平行坐标图; 卷积神经网络

Research on Fault Diagnosis Method Inside and Outside Transformer Based on PCP and Improved CNN

HE Long, ZHU Yongming, MA Jincai, LIU Rong

(State Grid Xinjiang Electric Power Co., Ltd., Changji Power Supply Company,
Xinjiang Changji 831100, China)

Abstract: In order to effectively prevent the maloperation of transformer differential relays in non fault transient conditions, a kind of fast identification method to distinguish internal and external faults and their transient processes in transformers is proposed. Firstly, a method to visualize the three-phase differential time series is proposed by using parallel coordinate plot (PCP) to address the issue of potential noise in on-site monitoring data, which, at the same time of containing all fault information, ensures signal noise resistance. Secondly, improvements are made to the CNN: an ECA attention mechanism module is added to the feature extraction section, and the optimized multi kernel support vector machine is used to improve the softmax classifier of the convolutional neural network (CNN), enhancing the applicability of CNN to various fault scenarios classification and facilitating the diagnosis and identification of internal and external faults in transformers. Finally, a internal and external fault simulation model of transformer is set up to obtain such differential protection monitoring data as winding inter turn faults, wiring faults, excitation inrush currents, current transformer (CT) saturation ferromagnetic resonance and other faults. Based on this, a graphical fault sample set is set up, the proposed method in this paper is verified and compared with similar algorithms so to prove the superiority of the proposed method.

Keywords: transformer failure; parallel coordinate diagram; convolutional neural networks

0 引言

电力变压器是电网的重要组成部分,变压器的保护对电力系统的运行的可靠性和稳定性至关重要,差动保护由于其固有的选择性和灵敏度,已成为变压器重要的一次保护方案,对变压器故障的准确判断是保证差动保护正确动作的前提。为此,对变压器故障类型进行诊断,并与其他暂态干扰故障加以区别具有十分重要的工程意义。

变压器励磁涌流和电流互感器(current transformer, CT)在外部故障扰动下出现的饱和现象是影响差动保护的主要问题,由于变压器励磁涌流中的二次谐波分量比内部故障中的二次谐波分量多,因此二次谐波抑制法曾被广泛用于区分变压器的内部故障和励磁涌流。不过当CT出现饱和、并联电容内部故障期间,也会产生较高比例的二次谐波^[2],限制了二次谐波法的应用。此外,在采用新型材料现代变压器中,励磁涌流中的二次谐波含量已降低^[3],增加了二次谐波法的局限性^[4-7]。

随着人工智能算法的发展,国内外研究者利用了不同的智能算法来区分PT中的内部故障和励磁涌流。文献[8]结合人工神经网络(artificial neural network, ANN)和故障信号的频谱特征,利用小波分量的能量来区分内部故障和涌流;文献[9-10]和文献[11-13]分别提出了基于支持向量机(support vector machine, SVM)和决策树(decision tree, DT)的变压器保护措施;文献[14]中使用了概率神经网络(probabilistic neural networks, PNN)来检测PT运行中的不同情况;文献[15]提出了随机森林分类器(random forest classifier, RFC)来区分内部故障和涌流;文献[16-21]则先采用S变换、双曲S变换、小波变换(WT)来将提取励磁涌流及干扰信息瞬态扰动频谱特征,再使用DT、SVM、ANN和PNN进行分类。上述研究的瞬态故障常常由冲击性负载变化、电容器切换、变压器充电、感应电机启动、非线性负载使用等引起的,将电容器饱和与变压器励磁涌流放在同一框架下区别诊断方面的研究有限。此外,在上述文献中还没有对瞬态扰动进行过严格的研究。

考虑到包含有瞬态扰动的故障信号中,监测数据的中心频段不一定存在重叠,而且在实际工程中,因电磁环境较为复杂,采集信息常常会包含大量的噪声,此时利用频谱特征提取时会影响有用信息高频部分的特征表达,而且,采用差动监测数据时会有三相信号,采用频谱分析难以将三相信息同时包含在图谱中,平行坐标图是一种可以将高维

数据可视化的有力工具,利用PCP将三相差动数据图像化,不仅可以包含所有故障或干扰信息,还能够增强样本的抗干扰性,为辨识方法提供良好的数据基础。

相比传统的人工智能技术和机器学习算法,深度学习模型不再局限于先验知识,就可以进行自主学习获取较高的分类准确率^[22-24],近年来,对变电站差动保护及其他变电站装置信息的监测已经相对全面^[25-26],能够获取实时、海量的状态量、开关量等数据,为利用深度学习进行故障辨识和诊断提供了良好的条件^[27-29]。卷积神经网络(convolutional neural network, CNN)的卷积层能够对图像边缘特征有较好的平面感知能力,不过为了增强CNN对变压器故障及干扰样本图像轮廓特征感知能力,嵌入协调注意力(CA)机制,从通道和空间两个维度进行特征及关联信息挖掘,提高特征信息的提取的精确性和全面性,保证在后续辨识训练中特征信息不易丢失的同时,还能有效缓解辨识算法可能存在的高计算量问题。考虑到多场景样本分类和辨识方面,SVM则具有更高的检测精度^[30],将CNN与SVM相结合对变压器区内外故障加以辨识,发挥二者的优势,可望得到更高的检测准确率。

有鉴于此,本文提出一种基于(parallel coordinate polt, PCP)和改进CNN深度学习模型的变压器故障区分诊断方法,针对变压器及电流互感器运行所处的复杂电磁环境对监测信号造成噪声叠加的问题,先利用平行坐标图对差动信号监测信息进行可视化,增强多场景样本的抗噪性;再利用CNN和SVM联合模型对故障类型加以区分,其中CNN挖掘出各类故障或干扰图像轮廓特征以及全局隐藏关系特征;SVM则对各类场景图片加以辨识,二者联合构建变压器故障诊断模型;最后,搭建仿真模型,模拟各工况变压器内部故障、励磁涌流及CT饱和等瞬态干扰得到的大量仿真数据,对所提方法进行验证。

1 模型构建

1.1 变压器区内外故障诊断模型总框架

为更准确的区分变压器内外故障类型,提出一种增强平行坐标图和改进CNN的深度学习模型,通过对IED智能电子设备(intelligent electronic device, IED)监测差动电流数据经可视化后组成故障样本集合,再构建优化CNN-SVM模型完成故障诊断,实现站内外故障的辨识与定位。故障诊断的深度学习总框架见图1。




图1 基于改进CNN的变压器区内外故障诊断总框架

Fig.1 Total framework of transformer and line fault diagnosis based on improved CNN

图1所示总框架一共包括3个流程：

1)对变压器差动保护监测三相数据进行可视化。智能电子设备可以对变压器差动电流信号进行监测与采集,所获得的差动电流为三相时间序列信号,由于所监测的故障类型较多,只选择单一相时序数据进行特征提取有可能会丢失故障关键特征,为此要将三相时间序列同时进行可视化。峭度图等频谱分析方法仅能分析一维时序,为此选择平行坐标图将三维时间序列转换为二维图像,可以包含故障所有信息,此外,为了解决监测数据存在的噪声干扰,对平行坐标图加以增强,以保证图片信息的抗噪性;

2)搭建改进CNN特征提取模型。为了充分挖掘变压器内外各类故障差动监测故障样本的特征信息,采用反向传播算法确定卷积核,以最大限度捕捉故障特征,设置多个卷积层,每一层均进行提取特征,后续层级在前一层网路输出特征中进一步提取得到更为复杂特征:池化层增加有效通道注意力(efficient channel attention, ECA)模块加以改进,进行局部、全局通道交叉耦合,确定特征权重,再将权重加以融合输出到全连接层,强化不同种类故障图像之间微小的差异;全连接层则将各类故障特征与其标签相关联,为分类操作提供依据,分类器利


用多核 SVM 进行替代;

3)搭建优化 SVM 变压器故障辨识模型。将 CNN 原有的 Softmax 分类器用多核 SVM 进行替代,由于需要进行区内外多个故障的诊断,需要构建多个超平面,为了解决多核 SVM 参数 σ 与惩罚参数 C 最优组合的确定问题,需要对 SVM 进行参数优化,确定最佳的参数组合提高准确性,并最终输出变压器内部和外部等不同类型故障的诊断结果。


1.2 数据预处理

变压器差动信号为三相时间序列,内部故障和干扰波形的三相信号不尽相同,且都包含故障或者

干扰信息特征,虽然采用三维坐标系也可进行可视化,不过难以揭示信号特征与规律,且会增加计算机视觉算法的难度。平行坐标图是一种可以将高维信号可视化的便利方法,包含有坐标轴、数据点和连接线 3 大要素,其中坐标轴数据与数据维度相当,每一维数据都有一个坐标轴,多维度数据的坐标轴垂直平行;维度内数据点分布在坐标轴上,连接线将不同维度上的数据连接起来,形成数据点的轮廓,构建出二维图像。为了展示三维差动信号数据特征及其内在联系和规律,进行多次试验和比较后,得到不同类型故障的可视化结果见图 2。



(a) 变压器内部故障波形



(b) 变压器内部故障信号图像




图2 变压器内部故障及干扰差动信号图像化结果
Fig. 2 The imaging results of internal fault of transformer and interference differential signal

由图2可以看出,采用可视化后,变压器内部故障图像中,绕组间故障和匝间故障的图像在轮廓上有较大的相似性;而干扰信号图像中,电流互感器CT饱和、非线性负载投切以及电容器投切图像的 shape 具有较大相似性;变压器绕组对地故障和励磁涌流信号图像又具有一定的相似性。这些相似性增大了图像分类难度。为解决图像所具有的内类差异大而类间差异小的特性,导致变压器内外故障难以区分的问题,在卷积神经网络中的池化层

和全连接层之间引入自注意力机制,捕获图像类别与边缘之间的关联性,凸显各不同类间细微区别;在分类层引入SVM,并加对其参数加以优化选择,增强其故障分类与诊断能力。

1.3 CNN改进模型

CNN 则通过样本集合通过卷积、池化等操作,挖掘各类故障潜在信息,抽象各类故障特征。本文设计的CNN包含卷积层、池化层、注意力机制和全连接层。当输入层接收图像样本后,利用卷积核进

行如下操作:

$$\alpha_{ij} = f\left(\sum_{m=0}^{k-1} \sum_{n=0}^{k-1} \omega_{m,n} x_{i+m,j+n} + \omega_b\right) \quad (1)$$

式中: $f(\cdot)$ 代表激活函数; α_{ij} 提取的特征向量的元素; x_{ij} 为各类故障或干扰差动信号图像的第 i 行第 j 列元素; $\omega_{m,n}$ 为第 m 行第 n 列权重, ω_b 为偏置向量, k 表示卷积核尺寸, 卷积核尺寸采用反向传播算法进行确定^[31]。

为了充分挖掘故障特征信息, 设置卷积层深度为 D , 特征提取模型为

$$\alpha_{ij} = f\left(\sum_{d=0}^{D-1} \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} \omega_{m,n} x_{d,i+m,j+n} + \omega_b\right) \quad (2)$$

每一层均进行提取特征, 后续层级在前一层级输出特征基础上, 再进一步提取得到更为复杂和本质特征, 最终得到特征映射矩阵, 送入 CNN 池化层。

1.3.1 有效通道注意力模块

分析图 2 所示可视化结果, 发现各类故障或者干扰样本的图像轮廓最能体现各自特征, 同时为了兼顾图像内部特征, 在池化层和全连接层之间增设注意力机制模块, 考虑到池化降维和信息通道之间相互影响会使注意力网络(squeeze-and-excitation network, SENet)产生阻滞现象, 采用 ECA 模块加以改进^[32], 模块结构见图 3。




图3 ECA通道模块结构

Fig. 3 ECA channel module structure

图中, 图像样本经卷积操作后, 还没经过池化降维的特征矩阵为 $X \in R^{H \times W \times C}$, 其中 $H \times W$ 为特征矩阵规模, C 为通道维度, 经过全局平均池化(global average pooling, GAP)操作后, 送入注意力通道, ECA 模块会对故障及干扰波形图像特征进行通道交叉耦合, 进一步融合注意力权重, 公式为

$$\omega = \sigma(C_1 D_{k_1}(y)) \quad (3)$$

式中: $\sigma(\cdot)$ 为 Sigmoid 函数; $y \in R^{C \times C}$ 为注意力通道矩阵, 是全局平均池化(global average pooling, GAP)的结果, 且有 $y = \frac{1}{WH} \sum_{i=1,j=1}^{W,H} X_{ij}$; $C_1 D_k$ 为 ECA 模块的一维卷积操作, k_1 为一维卷积核尺寸。可见, ECA 模块中只涉及到 k 参数, 选择合适的卷积核尺

寸, 通过适当捕获局部跨信道交互, 可以保证注意力模块 ECA 的效率和有效性。

全连接层将所有的特征连接在一起, 通过权重计算特征函数, 将故障特征映射到一维固定长度的特征向量后再送入分类器。

1.3.2 优化 SVM 分类器

CNN 输出层中常用 Softmax 分类器由多核 SVM 替换, 多核 SVM 需要构建多个超平面对多种类型加以划分, 为了保证分类误差最小, 基于结构风险最小原则, 可以构建划分多类型超平面的最优模型:

$$\min_{\omega, b, \xi_i, \hat{\xi}_i} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i) \quad (4)$$

式中: C 为惩罚参数, 值过大, 模型会发生过拟合, 过小又会导致模型越欠拟合; $\{\xi_i\}_{i=1}^n$ 和 $\{\hat{\xi}_i\}_{i=1}^n$ 为松弛变量, 考虑到存在不能被分类超平面正确分类的样本, 对松弛向量进行下述约束:

$$\begin{cases} y_i - \omega \varphi(x) - b \leq \varepsilon + \xi_i \\ \omega \varphi(x) + b - y_i \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, n \end{cases} \quad (5)$$

式中, $\varepsilon (\varepsilon > 0)$ 为不敏感损失系数。引入拉格朗日乘子数后, 求偏导可得到 SVM 非线性映射表达式为

$$f(u_k) = \sum_{j=1}^n (\alpha_j - \hat{\alpha}_j) K(u_{kj}, \hat{u}_k) + b \quad (6)$$

式中: $\alpha_i, \hat{\alpha}_i, \mu_i, \hat{\mu}_i$ 为拉格朗日乘子; $K(u_{kj}, \hat{u}_k)$ 为核函数, 定义式为

$$K(u_{ki}, u_{kj}) = \exp\left(-\frac{1}{2\sigma^2} \|u_{ki} - u_{kj}\|^2\right) \quad (7)$$

式中: σ 为核函数的内核参数, σ 越大预测越准确, 但会导致运行时间过长占用内存开销过大的问题, σ 越小则会存在较大误差, 合适的 $[\sigma, C]$ 组合可保证超平面离距离最远的样本点达到“距离”最小。可以用黑燕鸥优化算法(sooty tern optimization algorithm, STOA)优化算法来实现 $[\sigma, C]$ 参数组合迭代寻优。

STOA 对 SVM 核心参数 $[\sigma, C]$ 组合寻优的过程也是模拟黑燕鸥通过迁徙和攻击行为逼近猎物的过程, 其中, 黑燕鸥迁徙过程可表示为

$$\dot{C}_{st}(z+1) = S_A \times \dot{P}_{st}(z) \quad (8)$$

式中: $\dot{C}_{st}$ 是搜索到的与其他黑燕鸥不发生碰撞的位置; $\dot{P}_{st}$ 表示黑燕鸥当前位置; z 表示迭代次数; S_A 为黑燕鸥在给定搜索空间中的移动量。

黑燕鸥攻击猎物行为可表示为

$$\begin{cases} x' = \text{Radius} \times \sin(i) \\ y' = \text{Radius} \times \cos(i) \\ z' = \text{Radius} \times i \\ r = u \times e^{kv}(i) \end{cases} \quad (9)$$

式中: Radius 表示螺旋线每一圈的半径; i 为介于 $[0, 2\pi]$ 之间的变量; u 和 v 是用于定义螺旋形状的常数。结合迁徙与攻击特性,则黑燕鸥的位置更新可表示为

$$\bar{P}_{\text{bst}}(z+1) = (D_{\text{st}} \times (x' + y' + z')) \times (P_{\text{st}}(z)) \quad (10)$$

式中: $\bar{P}_{\text{bst}}$ 即为黑燕鸥最终最佳更新位置,对应 SVM 参数 $[\sigma, C]$ 的最优组合,以保证式(4)达到最小值。

1.4 基于PCP预处理与改进CNN变压器内外故障诊断流程

基于 PCP 预处理与改进 CNN 变压器内外故障诊断流程见图 4,具体步骤如下:

1)整理变压器内部故障和外部干扰时的差动电流 IED 监测信号,对其进行清洗后保留有效波形

信号,再利用 PCP 对有效信号进行可视化,构建图像样本集合;

2)搭建含 ECA 模块的 CNN 特征提取模型,反复测试,确定 CNN 学习率、卷积层数和各环节参数,将测试集样本序列输入 CNN,经过卷积、ECA 模块挖掘各类故障及干扰信号图像特征,经全连接层输出特征序列;

3)根据初始化的参数,结合训练集样本,利用 STOA 对 SVM 的参数组合进行寻优,确定参数组合;

4)根据 STOA 寻优参数组合,对训练样本进行分类,并判断迭代次数是否满足要求,如果否,重复第 2)~6),直至上述要求均达到满足,如果是,则转入第 5);

5)判断分类精准度是否满足要求,如果满足要求则转入第 6),否则回到第 2),调整 CNN 参数,直至满足精准度要求;

6)测试变压器故障模型,分析其故障诊断精准率,输出分类结果,并对模型进行评价。




图4 变压器内外故障诊断流程
Fig. 4 Diagnosis process for faults inside and outside transformer

2 算例分析

2.1 数据获取

双绕组结构变压器每相由两侧绕组构成,绕组和线圈之间绝缘作用可等值为多个串联电感和并联电容组成的形式,具体参见图 5(左)。

图 5(左)中, P_1, P_2 分别为变压器原、副边侧电

流, U_1, U_2 分别为变压器原、副边侧电压;虚线部分为原边绕组匝间短路示意图及其对应的集总参数等值电路, $M', M'_{n-2, n-1}$ 分别为原、副边侧绕组间互感和原边侧正常匝与故障匝之间的互感,事实上,各匝线圈之间都有互感,为简洁起见图中仅绘制出两个互感。

图 5(左)等值电路中,变压器绕组每匝线圈由感抗支路、容抗支路和电阻支路支路构成。 R_{ik}, C_{ik}

为绕组各匝绝缘等值电阻和电容参数,其中电容参数主要包括了绕组线匝之间的匝间电容和线饼之间电容等轴向电容参数,与匝间和线饼间绝缘材料及其等值介电常数有关,表征绕组线圈导体之间的绝缘作用,匝间和线饼间绝缘正常时, R_{ik} 支路可视为开路。 r_{w1} , L_{w1} 分别为原边侧绕组各匝等值电阻和电感参数, $C_{g,i}$ 为第 i 匝线圈的径向电容,包括绕组与绕组之间、绕组与油箱、绕组与地之间的电容,反应绝缘材料及其等值介电常数的绝缘特性。变压器原边侧绕组短路匝与短路电阻 R_d 构成回路,匝间绝缘击穿的程度可以通过调整电阻 R_d 的大小来控制,匝间绝缘劣化情况可以通过调整匝间电阻 R_{ik} 和电容 C_{ik} 的大小来体现,绕组对地绝缘劣化可通过调整径向电容 $C_{g,i}$ 来实现。

图 5(右)为某配电网 35 kV 变电站接线图,图

中 IED1、IED2 为智能电子设备,对变压器 T_1 、 T_2 的差动电流信号进行监测。

整个数据集由两部分构成,一部分数据来源于作者自行搭建的如图 5 所示的变压器内部故障仿真模型,分别模拟各种工况下的引线故障、绕组对地故障、绕组间故障以及匝间故障。仿真持续时间、故障/扰动开始时间和故障持续时间均取为一致。在做了大量仿真实验后,得到了如表 1 所示故障样本,各样本采样频率一致。

另一部分数据来源于 IEEE Dataport 上提供的数据^[33],包括有 CT 饱和、非线性投切、电容器投切和励磁涌流 4 种瞬态扰动,所有扰动样本通过所记录差动电流的信息表示。所有数据均为 1.5 个周期,时间序列长度均为 726。基于变化检测器记录的 1.5 个周期的三相差动电流,采用 PCP 进行可视化,结果如图 6 所示(部分样本)。





图 5 变压器接线(右)及其绕组匝间绝缘故障等值电路(左)
Fig. 5 Transformer wiring (the right) and its winding inter-turn insulation fault equivalentent circuit(the left)

表 1 故障参数设置
Table 1 Fault parameter settings

故障位置	编号	故障类型	工况描述	样本数量
区内故障	1	引线故障	一次侧、二次侧引线故障,包括单相引线对中性点故障和引线间故障	2 160
	2	绕组对地故障	绕组对地故障,故障电阻(0.01,0.5,10)Ω;绕组短路部分(20%,40%,60%,80%)	2 160
	3	绕组间故障	绕组间故障,故障电阻(0.01,0.5,10)Ω;绕组短路部分(20%,40%,60%,80%)	4 320
	4	匝间故障	匝间故障,故障电阻(0.01,0.5,10)Ω;绕组短路部分(20%,40%,60%,80%)	8 640
区外故障	5	CT饱和	外部故障电阻(0.01,0.5,10)Ω;故障类型包括单相接地、相间短路和两相短路接地;故障间隔取 1.67 ms。	7 920
	6	非线性负载投切	同期和非同期合闸方式,合闸相角 $\delta \in (0^\circ, 180^\circ)$,相角间隔 $\Delta\delta = 2.5^\circ$ 。	720
	7	电容器投切	同期和非同期合闸方式,合闸相角 $\delta \in (0^\circ, 180^\circ)$,相角间隔 $\Delta\delta = 2.5^\circ$ 。	720
	8	励磁涌流	同期和非同期合闸方式,合闸相角 $\delta \in (0^\circ, 180^\circ)$,相角间隔 $\Delta\delta = 2.5^\circ$ 。	1 800






图6 相同初始工况下不同故障差动信号可视化结果(部分样本)
Fig. 6 Visualization result of differential signals of different faults under the same initial conditions (partial samples)

针对变电站故障诊断模型及其诊断测试结果,本文采用精确率(Precision)、查全率(Recall)、 F_1 值(F_1 -score)和查准率(Accuracy)进行评价如下:

$$\begin{cases} \text{Precision} = \frac{TP}{TP + FP} \\ \text{Recall} = \frac{TP}{TP + FN} \\ F_1\text{-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \\ \text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \end{cases} \quad (11)$$


式中:精准率用 TP 、 FP 计算,其中 TP 、 FP 分别为真正类和假正类; TN 、 FN 分别为真反类和假反类。其中,精确率主要衡量各类样本被正确诊断的程度,其值越大,表明该类样本被准确诊断出来的比例越高;查全率用于评估故障类被正确预测占该类别故障样本数量的百分比, F_1 值综合了精确率和查

全率,是两者的加权调和平均值,可用于评估模型的质量, F_1 值越大则说明试验方法越有效,查准率表征正确分类的样本数与总样本数的百分比。上述评价结果将通过混淆矩阵展示。


2.2 模型验证

搭建改进后的CNN模型,配置CNN卷积核设置为大小为 3×3 ,激活函数选择ReLU;批量归一化通道为16个,池化层取全局最大池化方式,再利用ECA模块进行特征权重的融合后,经全连接层送入多核优化SVM加以分类。

先取2.1节处理后的样本集中每类样本各700个,采用 k -折交叉验证法,经过多进行训练,实现变压器内外故障分类诊断,其中10-fold诊断结果如下图7(a)所示,5-fold~10-fold的误诊率与学习周期关系如下图7(b)所示。图中故分类编号对应的具体故障或干扰参见表1。



(a) 10-fold 混淆矩阵(96.557%)



(b) 5-10 折误诊率与学习周期关系曲线

图7 变压器内外故障诊断结果与误诊率变化曲线
Fig. 7 Fault diagnosis results inside and outside transformer and variation curve of misdiagnosis rate

表 2 为采用 5-fold~10-fold 的变压器故障诊断指标结果。

表 2 交叉验证诊断指标
Table 2 Cross verification diagnostic data

验证方法	5-fold	6-fold	7-fold	8-fold	9-fold	10-fold
精确率/%	95.924 2	95.694 6	96.440 9	96.383 5	96.498 3	96.555 7
F_1 -score	0.977 1	0.978 5	0.972 2	0.969 7	0.987 7	0.975 6

结合图 7 和表 2 可知,本文方法在采用交叉验

证法时,对变压器故障类型诊断的综合精确率均可以达到 95% 以上。

为了检验 CNN 的改进效果,采用所有经 PCP 图像化后的样本,测试样本和训练样本分别为 30%与 70%。分别用 SVM、CNN-SVM 对变压器故障进行诊断,同时为了与同类算法作对比,将 BiLSTM-SVM 算法的诊断结果也一并给出。具体如图 8 所示。




图 8 不同模型的诊断结果
Fig. 8 Diagnostic results of different models

图8可见,采用SVM对变压器内外故障进行区分时,精确率为84.8%,将CNN与SVM结合,利用了CNN特征提取的优势后再进行分类,可以有效提高诊断精确率,相比SVM的结果提高了4.3%,但对CT饱和扰动的分辨率偏低,只有77.7%;为此对CNN增加有效注意力机制模块,将精确率提高到了91.3%,为了进一步提高辨识精确率,又利用STOA对SVM的参数进行了优化组合,对CT饱和的辨识提高到了92.7%,最终将精确率提高了96.9%,最终表明了所提方法的确能够增强CNN特征提取能力和SVM的分类能力。

2.3 方法抗噪性检验

接下来,对PCP抗噪能力进行验证,变压器差动电流原始信号添加不同比例的噪声干扰,得到不同信噪比下的波形,其中,信噪比 $SNR=15$ dB时的差动信号利用PCP方法可视化后结果见图9。

图9可见,添加随机噪声后,虽然差动电流信号波形有明显的变形,但经过PCP可视化后,所得到的图像仍然能够保持原始信号的轮廓。

分别设置信噪比 $SNR \in [90, 80, 70, 60, 15]$ dB,利用所提方法对变压器故障进行诊断,与CNN-SVM和BiLSTM-SVM的诊断结果进行对比,不同信




图9 添加噪声后的波形与可视化结果(部分样本)

Fig. 9 Waveform and visualization result after addition of noise (partial samples)

噪比下3种方法故障诊断见图10。




图10 不同信噪比下3种方法故障诊断精准率

Fig. 10 Fault diagnosis accuracy rate of three methods under different SNR

由图10可看出,在SNR从90 dB下降到15 dB的过程中,所有方法的故障诊断精准率均有所降低,不过下降趋势均较为平缓,论文方法精准率下降不足2个百分点,故障诊断综合精准率在2个百分点左右,可见经PCP可视化后,噪声对故障诊断的影响不大,提高了模型对噪声的耐受能力性。

3 结语

针对变压器内外故障诊断研究偏少以及机器学习存在提取故障特征方法复杂的问题,提出了一种基于PCP和改进CNN的变压器故障诊断方法。经过算法测试,得到如下结论:

1)利用PCP方法对变压器三相差动电流波形降维可视化,并将可视化后的图像组合构建样本集合,经过算法测试,能够增强辨识方法的抗噪性;

2)提出了一种融合有效注意力机制ECA的CNN特征提取改进方法,将CNN卷积层与池化层得到的结果,再进行多通道交叉融合,强调样本重要特征,舍弃无关信息特征,结果表明,增加ECA模块后,同样的样本集合,所提方法的分类诊断精度高出增加ECA模块时5个百分点,可见,ECA能够有效凸显不同类间样本的特征区别,增大类间特征相异性;

3)利用多核优化SVM替代CNN分类器,采用同样的样本集合,对变压器故障进行诊断,结果表明,所提方法比CNN-SVM和BiLSTM-SVM方法的辨识精准率均高至少5个百分点,证明了优化方法的优越性。

参考文献

- [1] HAMILTON R. Analysis of transformer inrush current and comparison of harmonic restraint methods in transformer protection[J]. IEEE Transactions on Industry Applications, 2013, 49(4): 1890-1899.
- [2] LIU Pei, MALIK O P, CHEN Deshu, et al. Improved oper-

ation of differential protection of power transformers for internal faults[J]. IEEE Transactions on Power Delivery, 1992, 7(4): 1912-1919.

- [3] SIDHU T S, SACHDEV M S, WOOD H C, et al. Design, implementation and testing of a microprocessor-based high-speed relay for detecting transformer winding faults[J]. IEEE Transactions on Power Delivery, 1992, 7(1): 108-117.
- [4] D BI Y S L Y W, WANG W. Analysis on maloperation of differential protection caused by sympathetic inrush[J]. Autom. Elect. Power Syst, 2007, 31(11): 36-40.
- [5] STANBURY M, DJEKIC Z. The impact of current-transformer saturation on transformer differential protection[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1278-1287.
- [6] IBRAHIM M A, F. P. STACOM phase angle regulating transformer protection[J]. IEEE Transactions on Power Delivery, 1994, 9(1): 394-404.
- [7] 李发永,薛继印,燕飞东,等.一起750 kV变压器运行过程中氢气超标问题故障分析[J]. 变压器, 2023, 60(1): 48-52.
- [8] LI Fayong, XUE Jiyin, YAN Feidong, et al. Fault analysis of a 750 kV transformer H₂ exceeds standard during operation[J]. Transformer, 2023, 60(1): 48-52.
- [9] MAO PI, AGGARWAL R K. A novel approach to the classification of the transient phenomena in power transformers using combined wavelet transform and neural network[J]. IEEE Transactions on Power Delivery, 2001, 16(4): 654-660.
- [10] SHAH A M, BHAIJA B R. Discrimination between internal faults and other disturbances in transformer using the support vector machine-based protection scheme[J]. IEEE Transactions on Power Delivery, 2013, 28(3): 1508-1515.
- [11] OZGONENEL O, S. KARAGOL. Power transformer protection based on decision tree approach[J]. IET Elect. Power Appl, 2014, 8(7): 251-256.
- [12] SAMANTARAY S, P. DASH. Decision tree based discrimination between inrush currents and internal faults in power transformer[J]. International Journal of Electrical Power & Energy Systems, 2011, 33(4): 1043-1048.
- [13] SHENG Yong, ROVNYAK S M. Decision trees and wavelet analysis for power transformer protection[J]. IEEE Transactions on Power Delivery, 2002, 17(2): 429-433.
- [14] M TRIPATHY R P M, VERMA H K. Probabilistic neural-network-based protection of power transformer[J]. IET Elec-

- tric Power Applications, 2007, 1(5): 793 - 798.
- [15] SHAH A M, B. R. BHAIJA. Fault discrimination scheme for power transformer using random forest technique[J]. Let Generation Transmission & Distribution, 2016, 10(6): 1431-1439.
- [16] KUMAR R, SINGH B, SHAHANI D T, et al. Recognition of power - quality disturbances using S - transform - based ANN classifier and rule-based decision tree[J]. IEEE Transactions on Industry Applications, 2015, 51(2): 1249-1258.
- [17] PERERA N, RAJAPAKSE A D. Recognition of fault transients using a probabilistic neural-network classifier[J]. IEEE Transactions on Power Delivery, 2011, 26(1): 410-419.
- [18] SANTOSO S, POWERS E J, GRADY W M, et al. Power quality disturbance waveform recognition using wavelet-based neural classifier. I. theoretical foundation[J]. IEEE Transactions on Power Delivery, 2000, 15(1): 222-228.
- [19] ZHONG Tie, ZHANG Shuo, CAI Guowei, et al. Power quality disturbance recognition based on multiresolution S-transform and decision tree[J]. IEEE Access, 2019, 7: 88380-88392.
- [20] SINGH U, SINGH S N. Optimal feature selection via NSGA - II for power quality disturbances classification[J]. IEEE Transactions on Industrial Informatics, 2018, 14(7): 2994-3002.
- [21] RAY P K, MOHANTY S R, KISHOR N, et al. Optimal feature and decision tree-based classification of power quality disturbances in distributed generation systems[J]. IEEE Transactions on Sustainable Energy, 2014, 5(1): 200-208.
- [22] 杨耿杰,王康,高伟. 基于相空间重构和迁移学习的配电网高阻接地故障检测[J]. 电力系统保护与控制, 2022, 50(13): 151-162.
- YANG Gengjie, WANG Kang, GAO Wei. High impedance fault detection in a distribution network based on phase space reconstruction and transfer learning[J]. Power System Protection and Control, 2022, 50(13): 151-162.
- [23] WEI Mingjie, LIU Weisheng, SHI Fang, et al. Distortion-controllable arc modeling for high impedance arc fault in the distribution network[J]. IEEE Transactions on Power Delivery, 2021, 36(1): 52-63.
- [24] 王宾,耿建昭,董新洲. 基于介质击穿原理的配电线路高阻接地故障精确建模[J]. 电力系统自动化, 2014, 38(12): 62-66.
- WANG Bin, GENG Jianzhao, DONG Xinzhou. High-impedance fault modeling based on solid dielectric electrical breakdown theory[J]. Automation of Electric Power Systems, 2014, 38(12): 62-66.
- [25] S. K. BHASKER, P. K. BERA, V. KUMAR, et al. Differential protection of indirect symmetrical phase shift transformer and internal faults classification using wavelet and ANN[C]// Proc. IEEE Region 10 Conf., 2015(11): 1 - 6.
- [26] P. K. BERA, R. KUMAR, C. ISIK. Identification of internal faults in indirect symmetrical phase shift transformers using ensemble learning[C]//Proc. IEEE Int. Symp. Signal Process. Inf. Technol., 2018: 1 - 6.
- [27] WANG Lei, LIU Zhiwen, CAO Hongrui, et al. Subband averaging kurtogram with dual-tree complex wavelet packet transform for rotating machinery fault diagnosis[J]. Mechanical Systems and Signal Processing, 2020, 142: 106755.
- [28] YOU Y, ZHANG Z, HSIEH C J, et al. 100-epoch imageNet training with AlexNet in 24 minutes[J]. Journal of Jinggangshan University, 2016, 33(6): 1020-1026.
- [29] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large - scale image recognition[J]. Computer Science, 2014, 36(1): 231-235.
- [30] K. MORI, M. MATSUGU, T. SUZUKI. Face recognition using SVM fed with intermediate output of CNN for face detection[C]//Proceedings of the IAPR Conference on Machine Vision Applications, Tsukuba Science City, Japan, May 2005: 410 - 413.
- [31] 徐瑾. 基于进化优化卷积神经网络的图像识别方法研究[D]. 重庆: 重庆邮电大学, 2020.
- [32] WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: efficient Channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]: IEEE, 2020: 11531-11539.
- [33] BERA P K, ISIK C, KUMAR V. Discrimination of internal faults and other transients in an interconnected system with power transformers and phase angle regulators[J]. IEEE Systems Journal, 2021, 15(3): 3450-3461.
- 作者简介:**
- 何龙(1988—),男,高级工程师,主要从事高压电气设备故障诊断研究工作。E-mail: helong69@126.com。
- 朱咏明(1973—),男,高级工程师,主要从事电气设备智能化、数字化工作。
- 马金财(1975—),男,本科,主要从事变电高压设备状态检修、故障诊断工作。E-mail: 860731525@qq.com。