

基于深度卷积神经网络的变电一次设备故障检测方法

张飞飞¹, 张俊¹, 吴龙¹, 吴晓辉², 雪占波²

(1. 国网昌吉供电公司, 新疆 昌吉 831100; 2. 宝鸡市韦思特电气有限公司, 陕西 宝鸡 721006)

摘要:为解决传统变电一次设备故障检测方法中存在的故障检测误报率及漏报率等问题,提出了基于深度卷积神经网络的变电一次设备故障检测方法。在多种光照条件下采集变电一次设备图像和场景图像,组建变电一次设备数据集合场景数据集,再对各类型数据集进行预处理。通过深度卷积网络自适应方法提取变电一次设备的时域和频域信号特征,将深度卷积神经网络作为特征提取器,利用免疫学习特性形成未知故障检测器,实现变电一次设备故障检测。实验结果表明:所提方法能够有效降低变电一次设备故障误报率和漏报率,切实提高了检测及时性和故障辨识度。

关键词:深度卷积神经网络;变电一次设备;故障检测;信息采集;预处理

中图分类号:TM213 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd23347

Fault Detection Method of Substation Primary Equipment Based on Deep Convolutional Neural Network

ZHANG Feifei¹, ZHANG Jun¹, WU Long¹, WU Xiaohui², XUE Zhanbo²

(1. State Grid Changji Power Supply Company, Changji 831100, Xinjiang, China;

2. Baoji West Electrification Co., Ltd., Baoji 721006, Shaanxi, China)

Abstract: In order to solve the problems of false alarm rate and missing alarm rate in the traditional fault detection method of substation primary equipment, a fault detection method of substation primary equipment based on deep convolution neural network was proposed. The substation primary equipment image and scene image were collected under a variety of lighting conditions, and the substation primary equipment data set and scene data set were set up, and then the various types of data sets were preprocessed. The time domain and frequency domain signal features of substation primary equipment were extracted by deep convolution neural network adaptive method. The deep convolution neural network was used as the feature extractor, and the unknown fault detector was formed by using immune learning characteristics to realize the fault detection of substation primary equipment. Experimental results show that the proposed method can effectively reduce the false alarm rate and missing alarm rate of substation primary equipment, and effectively improve the detection timeliness and fault identification rate.

Key words: deep convolutional neural network; substation primary equipment; fault detection; information collection; preprocessing

随着科学技术的飞速发展,电网工程成为社会发展的重要助力,变电设备自动化和智能化程度越来越高^[1]。变电设备的智能化发展为其故障检测维修造成一定程度上的阻碍。电网运行过程中受到多种因素的影响,变电设备超负荷工作等诸多因素,导致变电一次设备出现多种故障^[2]。为保障电网的正常运行,对变电一次设备故障的

维护和故障检测十分重要。为此,相关研究者进行了很多研究,并取得了一定成果。

尹相国等人^[3]提出一种智能变电站设备故障检测方法。该方法主要通过几点保护实现变电设备故障检测。根据广义变比构建故障诊断模型,对各类型的故障进行诊断和分析。该方法操作过程简单,但考虑的变电设备故障影响因素较

基金项目:国网新疆电力有限公司科技项目(SGXJY00GHJS2000011)

作者简介:张飞飞(1985—),男,学士,工程师, Email:zff198504@163.com

少,存在故障检测效果不佳的问题。王同文等人^[4]提出智能变电站二次回路智能预警及故障诊断技术。该方法首先分析了智能变电站信息传输的特点,并构建物理链路设置合理协议,并构建变电设备的物理拓扑,并将构建的物理拓扑结构回路信息流向相应位置,在此基础上,构建变电设备故障专家数据库,将变电设备的运行状态作为判断依据,完成故障的诊断。该方法未过多考虑变电设备中噪声数据,存在故障检测精度低的问题。

为解决上述问题,本文提出基于深度卷积神经网络的变电一次设备故障检测方法。实验结果表明,所提方法不仅能够有效降低故障误报率和漏报率,同时还能够提升故障检测及时性和辨识能力。

1 变电一次设备数据采集和预处理

变电一次设备的数据采集主要通过高分辨率的数码相机和摄像头在多光照条件下采集变电设备图像。以此为依据,组建变电站场景数据集,增强样本多样性。在变电一次设备图像采集过程中,主要受采集设备以及环境等条件因素影响,采集全部图像均存在噪声以及对比较低等问题。另外,由于距离较远以及焦距大小不一等问题,导致图像中间大小和位置不确定。为了确保设备图像中设备大小以及位置等参数的一致性,需要对采集到的数据集进行处理。图像噪声对图像特征的提取具有很大的影响。对其进行预处理时删除数据集中无关信息和噪声,常见噪声包括:

1)高斯噪声。高斯噪声是符合概率密度函数的高斯分布噪声, n 维噪声分布主要取决于各随机变量的三个数学变量,分别为:数学期望、方差以及协方差函数^[5]。假设高斯噪声的宽相对平稳,则对应的严也十分平稳;假设是两个不相关的随机变量,则统计独立。

2)椒盐噪声。即脉冲噪声,主要由盐噪声和胡椒噪声组成。前者是一种高灰度噪声;后者是一种低灰度噪声。通常情况下两者噪声可以一起存在。其能够随机改变一些像素,在二值像素点变白,剩余像素点变黑。

3)量化噪声。量化噪声和输入数据集的信号类型不存在任何关联,主要是在量化过程中由量化误差形成噪声。

不同噪声需要采用不同去噪方法进行处理。本文采用均值滤波对采集的图像进行预处理。该方法是一种典型的线性滤波方法,主要用于识别数据集中目标,包含邻近像素点和自身的像素点。

采用均值替代的方式确定原始图像中各像素值,即需要处理像素点 $f(x,y)$,选择最终模板。由邻近像素组成所需要模板,即求解全部像素的平均值^[6],同时将其赋值到当前的像素点 $f(x,y)$ 中,能够获取该点对应的灰度值为

$$g(x,y) = \frac{1}{m} \sum f(x,y) \quad (1)$$

式中: m 为模板中包括原始像素在内的全部像素总数。

在获取的变电一次设备图像中,由于图像大小相同,在故障数据检测前期需要对各数据集进行预处理。在预处理过程中,需要将数据集缩小或扩大为最佳大小^[7-8],同时还需要通过数据增广技术降低网络拟合的风险。

通过数据增广方法对原始数据集进行随机旋转,形成全新数据集。虽然在图像和数据采集过程中需要全面考虑方位以及角度等多样性,但各变电设备具有一定随机性,需要将原始图像或者数据集进行旋转,有效消除样本多样性带来的不足,通过下述公式进行计算:

$$P = [p_1 \ p_2 \ p_3][\alpha_1\lambda_1 \ \alpha_2\lambda_2 \ \alpha_3\lambda_3]^T \quad (2)$$

式中: P 为获取的无噪点的变电设备故障数据; p_1,p_2,p_3 分别为不同的原始图像数据; $\alpha_1,\alpha_2,\alpha_3$ 分别为一级、二级、三级的变电设备数据旋转因子; $\lambda_1,\lambda_2,\lambda_3$ 分别为一级、二级、三级的变电设备数据复数常数。

在此基础上,由于均值滤波方法对图像的预处理中存在的局部噪声无法得到完全消除,因此借助协方差矩阵对图像中局部噪声进行进一步的删除,得到的结果为

$$P_{i+1} = \bar{\omega}(PG_i + \lambda)(PG_i\lambda)^T \quad (3)$$

式中: $\bar{\omega}$ 为图像局部噪声融合因子; G_i 为图像局部关键噪声值; P_{i+1} 为最终获取的无噪点的变电设备故障数据; λ 为不同级别的变电设备数据复数常数矩阵,即 $\lambda = [\lambda_1 \ \lambda_2 \ \lambda_3]$ 。

2 变电一次设备故障检测实现

深度学习在人工智能领域占据核心位置,主要将不同的特征进行抽象表述,同时自动提取研

究对象的特征。为了获取更加精准的故障检测结果,引入卷积神经网络进行故障特征提取,促使故障检测更加智能化。其中,自适应深度卷积神经网络故障检测过程如图1所示。

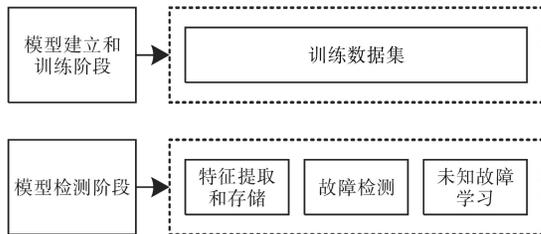


图1 自适应故障检测流程

Fig.1 Flow chart of adaptive fault detection

在训练初始阶段,故障诊断模型的建立是由以下步骤实现的:1)参数选择;2)输入信号图像;3)深度卷积神经网络模型建立。

在模型检测阶段也包含三个不同部分,分别为:1)特征提取和存储;2)组建检测器;3)未知故障学习。

在模型建立过程中,使用全连接层代替全卷积层。为了提取更加完整的故障特征^[9],需要将两个层进行统计。在抗体形成的过程中,采用基于抗原中心的抗体生成策略进行学习阶段抗体的寻优操作,有效避免错误检测情况的发生。

在变电一次设备故障检测的过程中,主要采用深度卷积神经网络进行故障特征提取和检测。深度卷积神经网络在建立过程中需要通过不同应用领域和检测对象选取合适网络模型,主要目的是为了有效提取检测对象的特征^[10],进而增强检测结果的准确性。

采用深度卷积神经网络时,需要优先解决网络建立和参数选择问题。在模型建立过程中,通过频域波形信号进行参数选择。在特征图个数选择过程中,需要设置不同类型的模型,具体如下所示:

1)增量模型。经过多次研究将各个卷积层的特征图提取数量设置为80,符合本文故障检测需求。

2)递减模型。各卷积层提取的特征图数量逐渐减少。

3)卷积操作。对波形信号进行特征提取,在选择好的卷积层中提取对应数量特征图数量,确定卷积核大小,其中共包含三种不同规格卷积核。

通过深度卷积神经网络选择好参数后,需要

进一步确定深度卷积神经网络的层数、输入时域以及频域波形信号的大小^[11]。模型中参数的训练需要通过时域和频域波形信号完成,以下给出具体的训练过程:

1)将振动信号设定为变电一次设备采集的数据。

2)将步骤1)中提取的振动信号转换为时域波形,通过傅里叶变换转换为频域波形,同时对其进行灰度化处理,将不同类型的信号分别存储到不同的文件夹中。

3)针对故障类型将文件夹存放到对应的位置。

4)建立时域和频域模型。

5)将数据集划分为测试集和训练集两种类型。

6)设定卷积操作的步长为1,池化核的步长为2,其中偏置数量和卷积层提取的特征图数量相同。

7)采用卷积核进行随机初始化操作,设定初始偏差为0。

8)通过不同类型的信号对网络进行训练,同时采用随机梯度下降的方式对网络模型进行训练。

9)通过测试集对训练好的网络模型进行训练。

在故障检测阶段,优先提取时域信号,同时经过傅里叶变换转换为频域信号,最终形成检测阶段的时域和频域信号。通过初试阶段检测后,将提取特征和初步诊断结果进行存储。

当变电一次设备进行故障诊断时,故障是在一段时间内连续出现的。为了促使检测结果准确性更好,需要对诊断结果的准确性进行评估。设定 TD 代表时域模型的检测结果, Fe_n 代表提取的特征属性,具体的计算式为

$$\text{Re}(T) = (TD, Fe_1, Fe_2, \dots, Fe_n) \quad (4)$$

式中: $\text{Re}(T)$ 为时域检测下的评估结果。

频域检测结果主要通过下式进行定义,即

$$\text{Re}(f) = (Fd, Fet_1, Fet_2, \dots, Fet_n) \quad (5)$$

式中: $\text{Re}(f)$ 为频域检测下的评估结果; Fd 为频域模型的检测结果; $Fet_1, Fet_2, \dots, Fet_n$ 为不同频域检测特征属性值。

其中,未知故障检测器的存储形式主要划分为如下两种:1)包含带标签位的抗体种群;2)不包含带标签位的抗体种群。

记忆故障知识库中故障检测器主要通过故障类别标签进行存储,各种故障类型均有其对应的标签以及抗体检测种群。采用记忆知识库中抗体进行检测时,如果时间和频率统计次数 T_{\max} 和 f_{\max} 两者均高于阈值,则通过标签位进行匹配。如果结果匹配,通过抗体对变电一次设备进行故障检测,假设完成检测,则能够反映当前的波形故障类型;反之无法完成检测,需要采用将存储特征进行抗体学习,组建新的故障检测器,使用形成故障检测器代替剩余检测器,这样不仅能够有效保持原有的故障检测器,同时还有新的检测器,促使检测器种群具有较强的动态适应性。当标签无法进行匹配时,则说明当前的故障波形在较近时间段内没有进行过学习,则需要执行抗体免疫学习过程,在此过程中通过对抗体初始化设置抗体抑制机制,可消除故障检测中无法匹配的特征冗余,提升一次设备故障检测的精度。该过程中形成抗体种群检测器,同时将统计标签和学习获取抗体种群存放到记忆故障知识库中。

如果变电一次设备出现未知故障,单纯使用记忆故障知识库无法完成故障检测,则需要使用抗体进行免疫学习,组建未知故障检测器。以下给出抗体免疫学习的具体操作过程:

1)将深度卷积神经网络时域和频域共同提取的特征转换为初始抗原种群 Agp 。

2)形成初始抗原后,通过抗体生成策略组建初始抗体种群。

3)分别计算各个抗体对全部抗原的平均亲和力,通过克隆操作定义各抗体克隆相应数量的抗体,当平均亲和力越大,说明抗体克隆数据越多;反之,则越少。

4)随机设定各个克隆抗体的概率阈值,通过计算获取变异概率,当其取值高于随机阈值时^[12],则对克隆抗体进行变异操作;反之,则不进行变异操作。

5)针对经过克隆和变异操作的抗体进行降序排序,同时设定下一代初始抗体种群。

6)重复步骤3)~步骤5),当迭代次数达到指定次数或抗体亲和力满足指定阈值时,则停止计算。

7)完成全部操作后,会形成全新的检测器,结合实际情况将新的检测器放入记忆故障知识库中进行故障检测。

3 实验分析

3.1 实验环境

为验证所提基于深度卷积神经网络的变电一次设备故障检测方法有效性,在 Intel i7-97006 核心处理器,16 GB 内存,操作系统为 64 位 Windows 10 操作系统下进行实验测试。实验以某变电站为研究对象,具体实验环境如图 2 所示。

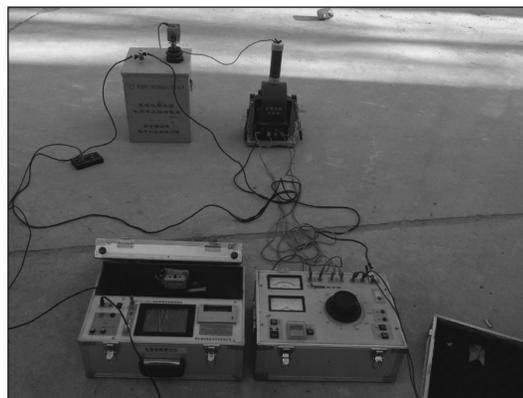


图2 实验环境

Fig.2 Experimental environment

3.2 实验参数

实验中使用的参数如下所示:图像采集光源条件为日光光源,样本源图像噪声 $-2\sim 2$ dB,样本图像数量 100 张。

3.3 实验指标

实验测试指标包括:

1)故障检测及时性。当变电一次设备发生故障后,在最短的时间内完成故障检测,其中故障检测及时性越短,说明检测速度越快。

2)故障误报率和漏报率。误报率主要是指故障检测方法将变电一次设备正常运行状态检测为故障状态;漏报率主要是指将变电一次设备的故障状态检测为正常状态。其中,漏报率和误报率的取值越小,说明系统的可靠性和安全性较高。

3)故障辨识能力。主要指故障检测方法检测故障程度的能力,其中辨识能力越强,则说明检测结果准确性越高,同时有利于对监测对象进行评估以及维修。

3.4 实验结果分析

为验证所提方法的有效性,实验对比了所提方法、文献[3]方法以及文献[4]方法对故障检测的及时性,得到的结果如图 3 所示。分析图 3 中实验数据可知,由于变电站一次故障类型不同,三种方法的故障检测时间也存在较大差异。其中,

所提方法对5种故障类型检测的耗时较短,始终低于其他两种方法。这是由于所提方法在进行故障检测时首先对故障数据进行预处理,减少了干扰数据的影响,从而提升了故障检测的及时性。

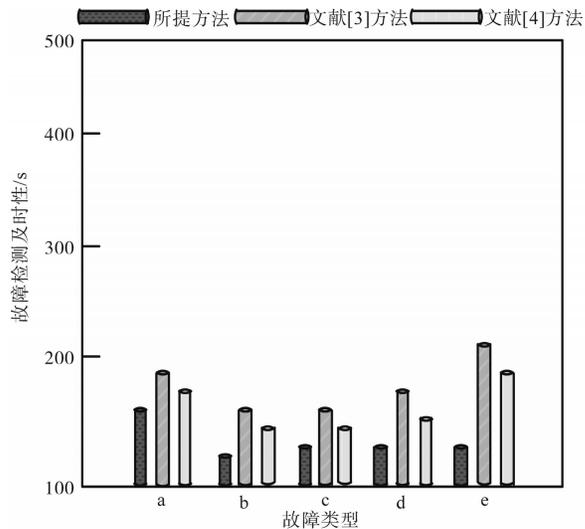


图3 不同方法故障检测及时性

Fig.3 Timeliness of fault detection by different methods

实验对比了所提方法、文献[3]方法以及文献[4]方法对故障检测的误报率和漏报率,实验结果表1和表2所示。

表1 不同方法故障误报率对比结果

Tab.1 Comparison results of false alarm rates of different methods

测试集序号	故障误报率/%		
	所提方法	文献[3]方法	文献[4]方法
001	0.021	0.047	0.051
002	0.014	0.064	0.075
003	0.031	0.052	0.106
004	0.026	0.073	0.114
005	0.015	0.065	0.092
006	0.024	0.054	0.107

表2 不同方法漏报率对比结果

Tab.2 Comparison results of underreporting rates of different methods

测试集序号	故障漏报率/%		
	所提方法	文献[3]方法	文献[4]方法
001	0.032	0.054	0.062
002	0.014	0.077	0.090
003	0.025	0.064	0.083
004	0.012	0.045	0.071
005	0.028	0.078	0.094
006	0.019	0.057	0.084

分析表1和表2中实验数据可知,由于所提方法在故障检测前期,对变电一次设备进行数据采集和预处理,为后续的故障检测奠定坚实的基础,进而有效降低了误报率和漏报率,获取更加

理想的检测结果,且明显优于另外两种方法。

为了进一步验证所提方法的优越性,实验对比三种不同方法的故障辨识能力,实验结果如图4所示。

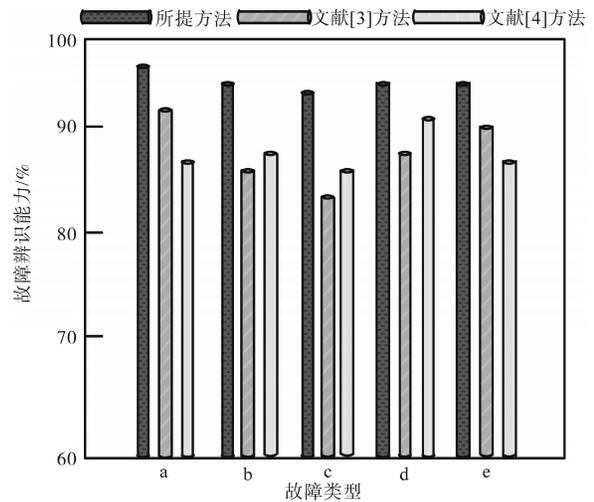


图4 不同方法故障辨识能力对比结果

Fig.4 Comparison results of fault identification capabilities of different methods

由图4中的实验数据可知,在相同实验环境下,采用三种方法对样本故障进行辨识的能力存在一定差距。其中,所提方法对样本故障辨识的能力最高达到了99%,满足对样本一次性设备故障诊断的需求,全面验证所提方法的有效性,同时也证明了本文方法在变电一次设备故障诊断中的优势。

4 结论

针对传统方法存在的一系列缺陷,本文提出一种基于深度卷积神经网络的变电一次设备故障检测方法。该方法通过深度卷积神经网络对故障进行检测,提升了故障检测的性能。实验结果表明,所提方法能够提升故障检测的及时性,降低故障误报率和漏报率,获取满意的故障检测结果。

参考文献

- [1] 张艳霞,尹佳鑫,蒙高鹏,等.基于错误逻辑区域检测的配电网容错故障定位[J].电机与控制学报,2017,21(11): 1-8.
Zhang Yanxia, Yin Jiaxin, Meng Gaopeng, et al. Fault tolerant fault location of distribution network based on fault logic region detection[J]. Journal of Electrical Machinery and Control, 2017,21(11): 1-8.
- [2] 杨高峰,谢兵,曾志安,等.基于SCD与CCD校准的智能变