

基于改进 SqueezeNet 算法的 VBE 设备电路板 元件失效识别研究

刘隆晨¹, 杨玥坪¹, 贾志杰¹, 黄宇², 唐世雄^{2,3}, 谭博洋^{2,3}

(1. 国网四川省电力公司电力科学研究院, 成都 610041; 2. 国网四川省电力公司特高压直流中心, 成都 610000; 3. 电力物联网四川省重点实验室, 成都 610041)

摘要: 在直流输电系统中, 换流阀基电子 VBE (valve base electronics) 设备的稳定运作对维护直流系统安全至关重要。传统的阀基电子设备电路板 (VBE 板) 元件失效检测方法依赖于耗时的人工检查或基于规则的自动化系统, 这些方法通常检测效率低下且准确性有限。针对该问题, 提出一种基于改进的 SqueezeNet 深度学习模型的 VBE 板元件失效区域识别方法。通过引入深度可分离卷积和残差连接, 所提改进 SqueezeNet 模型旨在提高元件失效检测的准确性, 同时降低计算资源的需求。在 VBE 板元件失效数据集上的实验结果表明, 所提方法在元件失效检测准确率和运算效率方面均优于传统方法和标准 SqueezeNet 模型, 准确率达到了 95.27%, 比原模型高出 4.45%。不仅提升了 VBE 板元件失效检测的效率和准确性, 而且为电力系统中类似设备的元件失效诊断提供了新的技术参考。

关键词: 阀基电子设备; SqueezeNet 模型; 元件失效检测; 特征提取

Research on Component Failure Identification in VBE Device Circuit Boards Using Enhanced SqueezeNet Method

LIU Longchen¹, YANG Yueping¹, JIA Zhijie¹, HUANG Yu², TANG Shixiong^{2,3}, TAN Boyang^{2,3}

(1. Electric Power Research Institute, State Grid Sichuan Electric Power Company, Chengdu 610041, China;

2. Ultra High Voltage DC Center, State Grid Sichuan Electric Power Company, Chengdu 610000, China;

3. Power Internet of Things Key Laboratory of Sichuan Province, Chengdu 610041, China)

Abstract: In a direct current (DC) power transmission system, the stable operation of a valve base electronics (VBE) device is crucial for its safety. However, the traditional methods for detecting the component failures in VBE device circuit boards rely on time-consuming manual inspections or rule-based automation systems, which are often inefficient and limited in the detection accuracy. To address this problem, a method for identifying the component failure areas in VBE boards is proposed in this paper, which uses an enhanced SqueezeNet deep learning model. By incorporating depth-wise separable convolutions and residual connections, the enhanced SqueezeNet model aims to improve the accuracy of component failure detection while reducing the demand for computational resources. Experiments on a VBE board component failure dataset demonstrate that the proposed method outperforms the traditional methods and the standard SqueezeNet model in terms of detection accuracy and computational efficiency, and it achieves an accuracy rate of

收稿日期: 2024-02-03; 修回日期: 2024-03-17, 2024-04-22;

录用日期: 2024-05-06; 网络首发日期: 2024-05-17

基金项目: 国网四川省电力公司科技项目 (52199723000B); 四川省自然科学基金资助项目 (2023NSFSC0818)

This work is supported by State Grid Sichuan Electric Power Company Science and Technology Project under the grant 52199723000B; Sichuan Natural Science Foundation Project under the grant 2023NSFSC0818

95.27%, which is 4.45% higher than that of the standard model. The results of this research not only enhance the efficiency and accuracy of component failure detection in VBE boards, but also provide a novel technical reference for the diagnosis of component failures in similar equipment in power systems.

Keywords: Valve base electronics (VBE) device; SqueezeNet model; component failure detection; feature extraction

在现代直流电力工程中, 阀基电子 VBE (valve

base electronics)设备起着至关重要的作用,可有效维持电力系统的电压平衡,确保直流运行稳定性和可靠性。VBE 设备控制系统的核心部件是阀基电子设备电路板(VBE 板),其元件失效可能导致电压不平衡,进而影响整个电力系统的运行。因此,对 VBE 板进行有效的元件失效检测和诊断是保障电力系统稳定性的关键。VBE 板的元件失效检测面临着多方面的挑战。首先,电力系统的复杂性和环境因素(如温度变化、机械磨损等)使得元件失效模式呈现多样化且难以预测。此外,VBE 板通常在高压、电流环境下运行,增加了检测系统的设计难度和安全风险。

传统的 VBE 板元件失效检测方法主要依赖于定期的人工检查或基于简单规则的自动化系统。这些方法不仅效率低下,而且容易受到主观判断的影响,导致准确性不足。例如,人工检查通常需要经验丰富的技术人员,且易受个人疲劳和注意力分散的影响;而基于规则的系统则难以适应电力系统的动态变化和复杂性,常常无法及时响应突发元件失效。

随着技术的发展,基于传统神经网络的方法也被尝试应用于 VBE 板元件失效检测。文献[1]使用基于多层感知机 MLP(multi-layer perceptron)的方法能够处理一定的非线性问题,但其在处理高维数据和复杂特征时效率低下。此外,文献[2]使用卷积神经网络 CNN(convolutional neural network)虽然在图像处理领域表现优秀,但在电力系统的元件失效诊断中,由于缺乏足够的训练数据和过度依赖于大量计算资源,其应用受到限制。文献[3]利用信号处理技术(如傅里叶变换)来分析 VBE 板的电压和电流信号,从而识别异常模式,然而这种方法在处理复杂的非线性元件失效信号时效果有限。例如,在多种元件失效模式交织的情况下,这些方法往往难以准确区分元件失效类型。文献[4]使用机器学习的方法对 VBE 板元件失效进行检测,但该方法通常需要大量的标注数据,并且在面对未见过的元件失效类型时性能明显下降,且在特征选择和参数调整方面需要大量的专业知识和手动干预,增加了实际应用的复杂性。

在此背景下,本文引入基于深度学习法,尤其是 SqueezeNet,提供了一种新的解决方案。SqueezeNet 以其轻量级结构和高效性能在图像识别领域获得广泛关注,其在减少模型参数的同时能够保持较高的准确度,适用于需要快速且准确处理的应用。然而,直接应用标准 SqueezeNet 进行 VBE 板元件失效检测无法完全满足特定的性能和精度要求,如文献[5]直接应用标准 SqueezeNet 进行 VBE 板元件失效检测,在识别电路短路或基本的电容元件失效方面表现出一定的效果,但在微小裂纹或初期电压偏差时,该模型可能无法准确地识别这些细微变化。因此,为了更好地应对这类复杂故障的检测,需要对标准 SqueezeNet 模型进行相应的改进和优化。

本文研究通过改进 SqueezeNet 模型,为 VBE 板元件失效检测提供一种更高效、更准确的方法,即通过引入深度可分离卷积,提出了一种改进的 Fire 模块,修改 Fire 模块中的 expand 层,替换成 Inception 模块增强模型在特征提取和泛化能力方面的性能,在保持模型轻量级特性的同时,大幅提升元件失效检测的准确性和速度。

1 传统方法的 VBE 板元件失效检测

1.1 VBE 板元件失效类型

(1)电容器老化:随着时间推移,电容器可能因介电材料退化、漏电流增加和容量减少而老化,减少其存储电荷的能力,可能导致 VBE 板电压不稳定,影响电路稳定性和性能。在图像中,电容器老化通常表现为膨胀、裂纹或泄漏痕迹,而健康电容器表面平整无瑕,实际失效图片如图 1(a)所示。

(2)二极管故障:二极管故障,如内部短路、断路或是运行和环境温度过高等会影响其整流或信号调制功能,可能导致过电流或电路功能受阻,影响 VBE 板正常运行。与其原始颜色和完整形态的健康二极管形成对比,二极管故障后会导致表面烧焦或颜色变黑,实际失效图片如图 1(b)所示。

(3)晶体管故障:晶体管的偏置不当、过热或过电压可能损坏 PN 结,导致开关控制失效,影响电

路的开关功能和信号放大能力。VBE 板中包含多个晶体管,它们共同协作以维持电压的平衡。当其中 1 个或多个晶体管失效时,电压平衡控制将受到影响,可能导致电路中的电压波动或不稳定。晶体管故障则表现为局部过热导致的颜色变化或物理损伤如裂纹,实际失效图片如图 1(c)所示。


(4)焊点故障:焊点质量问题,如未正确加热、开裂或受腐蚀等会导致电路连接不稳定,影响信号传输和电源分配,进而影响装置性能。这些故障类型表明,对 VBE 板进行有效的元件失效检测和诊断对维持电力系统的稳定性和可靠性至关重要^[9]。健康的焊点应该表现为清晰、均匀且与连接元件紧密结合的圆形或椭圆形斑点,与完好的焊点相比,焊点故障在图像中通常表现为焊接不良的迹象,如焊点断裂、焊料溢出或焊点形态不规则,实际失效图片如图 1(d)所示。



(a) 电容器故障



(b) 二极管故障



(c) 晶体管失效



(d) 焊点故障

图 1 元件失效类型

Fig. 1 Types of component failure

1.2 传统元件失效检测方法

当 VBE 板中的元件出现上述 4 种失效后,通常采用视觉检查、电参数测量等传统方法来检测元件失效。传统检测方法对于 VBE 板元件失效的识别依赖于仔细的目视检查和详细的电气性能测试,存在诸多局限性,需要结合先进技术以提高检测的准确性、效率和全面性,具体的传统检测技术与其优点和局限性如表 1 所示。

SqueezeNet 是一种深度学习架构,与传统的机器学习方法相比,其在处理图像识别,特别是在资源受限的环境中展现出显著的优势。首先,SqueezeNet 通过使用 Fire 模块,有效地减少了模型参数数量,同时保持了与更大网络相似的性能水平。这使得 SqueezeNet 不仅占用存储空间更少,还能以更低的计算成本实现快速推理,这对于嵌入式系统或移动设备等资源受限的应用场景尤为重要。与 ResNet、DenseNet 深度学习方法相比,SqueezeNet 虽然在参数规模和计算效率上具有优势,但在处理极其复杂的图像识别时可能会略显不足,但通过引入残差连接或密集连接等技术,可以增强特征的传递和重用,构建更深且高效的网络,从而实现更优的图像识别性能。

1.3 图像预处理在 VBE 板缺陷检测中的应用

VBE 板的主要作用是确保多个电压源(电池组、电容器组)在直流电路中均匀分配电压,其通过动态调整每个电压源的充、放电状态来实现^[9],以确保整个系统的电压平衡。1 个典型的 VBE 板包含了控制单元、电压检测单元和电荷转移单元等。其中,控制单元负责监测和管理整个系统,电压检测单元用于实时监测每个单元的电压水平,而电荷转移单元则负责在各单元间转移电荷以达到平衡。VBE 板通过算法决定何时、如何调整各单元的电荷状态,其通常涉及到复杂的电路设计和控制逻辑,以确保在不同的负载和充电状态下均能保持电压平衡。

1.3.1 图像灰度化

在本文研究中,为了有效地处理 VBE 板图像并使电子元件与背景之间的差异更加明显,采用了加权平均法进行灰度化处理。该方法的核心在于为

表 1 传统方法元件失效检测

Tab. 1 Traditional methods for component failure detection

检测技术	描述	优点	局限性
视觉检查	依赖技术人员的经验来识别元件的外观异常	简单直观,无需复杂设备	高度依赖检查者经验,可能漏检微小或内部故障
电参数测量	使用多用电表或专用测试仪器测量电阻、电流、电压等参数	提供定量数据,可评估元件性能	需要断开电路进行测量,无法实时监测
功能测试	在电路的正常工作条件下测试其功能	在实际工作条件下测试,模拟元件实际使用环境	对间歇性故障难检测,测试过程可能复杂
红外热成像	使用红外摄像机检测电路板上的热点	无接触、非侵入式检测,能迅速定位故障区域	无法准确识别故障原因,对环境温度敏感
振动分析	通过分析设备的振动模式来诊断故障	对机械部件故障(如轴承和齿轮)有效	主要用于机械系统,对电子元件故障检测有限
声发射分析	检测由裂纹或断裂产生的超声波信号	能检测到微小的损伤	对环境噪声敏感,需要专门设备和技术

红色(R)、绿色(G)和蓝色(B)通道的像素值分配不同的权重,并将其融合成单一的灰度值。具体的算法公式表达为:灰度值 $= (r_R + g_G + b_B) / 3$,其中 r 、 g 、 b 分别代表R、G、B通道的权重。经过详细的实验分析,本文确定了最优的权重配置为 $r_R=0.60$ 、 $g_G=0.79$ 、 $b_B=0.31$ 。该权重分配能够更有效地突出VBE板上的关键特征,从而为后续的缺陷检测提供更为清晰和准确的图像。

1.3.2 图像二值化

为了提高VBE板表面图像二值化处理的自动化水平、速度和准确性,本文采用了Otsu方法来自动确定最佳的二值化阈值。在分析VBE板图像时,Otsu算法通过计算图像中电子元件和背景像素点之间的类间方差,自动选定1个阈值,以实现最有效的像素分割。这一过程涉及计算电子元件像素(占比为 s_0 ,均值为 a_0)和背景像素(占比为 s_1 ,均值为 a_1)的统计特征^[7],以及整体图像的平均灰度值 a 。其中, a 由 $s_0 * a_0 + s_1 * a_1$ 得出。Otsu算法的目标是最大化类间方差,即

$$g(z) = s_0 * (a_0 - a)^2 + s_1 * (a_1 - a)^2 \quad (1)$$

式中, z 为分割阈值。当 $g(z)$ 达到全局最大值时,对应的 z 即为最佳二值化阈值。这种方法的优势在于免去了手动设定阈值的需求,大大提升了处理效率和自动化程度。

1.3.3 图像去噪及锐化

为了应对拍摄环境的复杂性及其产生的多种噪点,本文采用了腐蚀膨胀法进行有效的去噪处理。此方法通过应用2种不同的结构元素B矩阵对二值化图像进行腐蚀和膨胀操作,成功去除了白色噪点,特别是在感兴趣区域的白色噪点。这一步骤确保了VBE板缺陷检测算法的准确运行,避免了因噪点引起的误判。紧接着,本文使用Canny算子对图像进行锐化,以进一步增强边缘特征。

Canny边缘检测算法首先通过与非线性滤波模板的多次迭代运算来减少噪声,虽然这会使图像略显模糊,但显著减弱了噪声的影响。接着,算法计算灰度图像沿不同方向的梯度 G ,其表达式为

$$\begin{cases} |G| = \sqrt{G_x^2 + G_y^2} \\ \theta = \arctan\left(\frac{G_y}{G_x}\right) \end{cases} \quad (2)$$

然后,通过分析每个像素点的梯度方向与相邻像素点的灰度值,从而有效地识别出真正的边缘像素。该方法还包括使用直方图计算2个阈值,以进一步区分边缘和非边缘像素,优化边缘检测的准确性。

2 改进的 SqueezeNet 模型

2.1 SqueezeNet 神经网络

SqueezeNet 是一个轻量级的 CNN 模型,其设

计目标是在与 AlexNet 相似的性能水平下,大幅减少模型参数,达到 AlexNet 50 倍的压缩率。SqueezeNet 的设计具有 3 个显著特点:首先,为了减少计算量,SqueezeNet 创新性地用 1×1 卷积核替换了部分传统的 3×3 卷积核;其次,SqueezeNet 采用了 1 个独特的火箭模块(Fire Module)结构,其由挤压层(Squeeze Layer)和扩展层(Expand Layer)2 个部分组成。挤压层使用 1×1 卷积核来减少特征通道数,而扩展层结合 1×1 和 3×3 卷积核增加通道数,随后将这 2 种卷积核的输出特征合并,从而有效减少了网络的参数量;最后,SqueezeNet 通过将池化操作推迟到网络更深的层次来保留更大的特征图,以此保有更丰富的特征信息,图 2 展示了火箭模块的内部结构^[7]。




图 2 火箭模块的组成结构

Fig. 2 Composition structure of Fire Module

火箭模块是 SqueezeNet 架构的核心组成部分,由 2 层构成:挤压层和扩展层。挤压层仅使用 1×1 卷积核,而扩展层结合了 1×1 和 3×3 卷积核。在火箭模块中,挤压层的卷积核数目故意设计得少于扩展层,目的是减少进入 3×3 卷积核的输入通道数,从而有效降低网络参数的数量。

SqueezeNet 的网络结构如图 3 所示,其从 1 个单独的卷积层开始处理输入图像,然后输出特征依

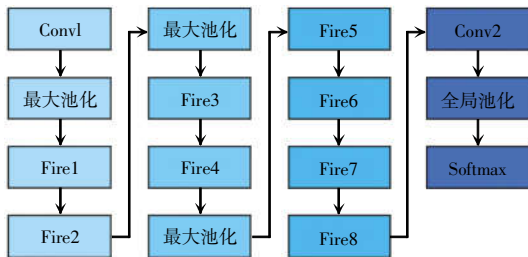


图 3 SqueezeNet 的网络结构


Fig. 3 Network structure of SqueezeNet

次通过 8 个火箭模块。在这些模块中,每个模块的卷积核数量逐渐增加。此外,SqueezeNet 在第 1 个卷积层(Conv1)、第 4 个火箭模块(Fire4)、第 8 个火箭模块(Fire8)及最后 1 个卷积层(Conv10)之后,均采用了步长为 2 的最大池化操作,以进一步优化特征提取过程^[8]。

2.2 改进的 SqueezeNet 神经网络

尽管 SqueezeNet 中的火箭模块通过在扩展层中使用 1×1 卷积核来替代部分 3×3 卷积核,有效地减少了模型的参数量,但计算量仍然较大。为了进一步降低 SqueezeNet 模型的参数数量和计算成本,本文提出了一种改进的火箭模块,重新设计原有火箭模块的扩展层,引入了 Ghost 模块,旨在进一步优化卷积层的结构,以实现更高效的参数使用和计算性能。通过这种改进,模型在保持原有性能的同时,能够以更低的计算复杂度运行,更适合于资源受限的应用场景。

本文所提改进的 Fire 模块,如图 4(b)所示,其在传统的 Fire 模块基础上,将 Fire 模块中的扩展层用 GoogLeNet 中的 Inception 模块替换,这不仅保留了原 Fire 模块的功能性,同时利用 Inception 模块的高效性在保持较低资源消耗的同时大幅减少了模型的体积,使其更加适合于资源受限的应用场景。



(a)火箭模块

(b)改进的火箭模块

图 4 火箭模块和改进火箭模块结构

Fig. 4 Structures of Fire Module and improved Fire Module

标准卷积核的参数个数 T_s 为

$$T_s = C_k \times C_k \times M \times N \tag{3}$$

式中: C_k 为卷积核大小; M 为输入通道数量; N 为输出通道数量。

因此,设 N_s 为挤压层的输出通道数, N_E 为扩展层的输出通道数, 则标准的 Fire 模块的参数 Q_{FIRE} 可表示为

$$Q_{\text{FIRE}} = M \times N_s + N_s \times \frac{N_E}{2} + C_k \times C_k \times N_s \times \frac{N_E}{2} \quad (4)$$

改进的 Fire 模块参数为

$$Q_{\text{FIRE}} = M \times N_s + C_k \times C_k \times N_s \times \frac{N_E}{2} + C_k \times C_k \times \frac{N_E}{2} \quad (5)$$

在卷积神经网络的设计中,卷积核的大小是影响参数量的一个关键因素。因此,在本文所提改进的 Fire 模块中,选择 1×1 的卷积核作为构建模块的主要元素。由于 1×1 卷积核相对于更大尺寸的卷积核(如 3×3 或 5×5)具有更少的参数,能显著减少整个网络的参数量。在 Fire 模块中, 1×1 卷积核的使用不仅降低了参数数量,还有助于减少计算复杂度,同时仍能有效地传递和融合特征信息。具体而言, 1×1 卷积核主要用于通道间的线性组合,减少后续层的输入通道数,从而降低整体网络的参数量和计算需求。Fire 模块的计算公式为

$$Q_{\text{FIRE}} = M \times N_s + N_s \times \frac{N_E}{2} + \frac{N_E}{2} \quad (6)$$

通过改进 Fire 模块,本文所提改进的 SqueezeNet 网络实现了参数量的显著减少。与原始的 Fire 模块相比,本文所提改进的 Fire 模块减少了 $(C_k \times C_k \times N_s - 1) \times \frac{N_E}{2}$ 的参数数量,其中 N_k 为卷积核的大小。这一改进,显著减轻了网络的计算负担,提高了运算效率。考虑到原始 SqueezeNet 中含有 8 个 Fire 模块,网络层数和参数量较多,导致运算时间较长,同时也增加了训练过程中出现过拟合的风险。为了解决这些问题,本研究在改进的 SqueezeNet 中移除了 Fire3、Fire5、Fire7 这 3 个模块。这一策略不仅进一步降低了网络的复杂性,也缩短了训练时间,同时有助于防止过拟合。GHSQNet 的整体架构如图 5 所示,其内部参数细节见表 2。可见,通过这些改进,GHSQNet 在保持了原有 SqueezeNet 网络性能的同时,实现了更轻量化和高效的网络结构,适合于计算资源受限的环境和实时处理需求。

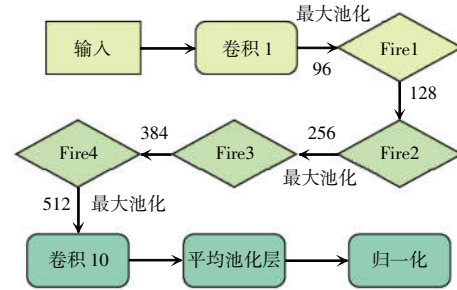


图 5 改进的 SqueezeNet 网络结构

Fig. 5 Structure of improved SqueezeNet network

表 2 改进的 SqueezeNet 网络的内部参数

Tab. 2 Internal parameters of improved SqueezeNet network

类型	输入层	卷积核大小	步长	输出层
卷积层	(32, 32, 3)	(3, 3)	1	(32, 32, 96)
池化	(32, 32, 96)	(2, 2)	2	(16, 16, 96)
Fire1	(16, 16, 96)			(16, 16, 128)
Fire2	(16, 16, 128)			(16, 16, 256)
全局平均池化层	(4, 4, 1 000)	(4, 4)	1	(1, 1, 1 000)
Softmax 层	(1, 1, 1 000)			(1, 1, 3)

2.3 改进的 SqueezeNet 模型学习率与 batch size 的选择

在神经网络训练过程中,学习率和批量大小(batch size)对网络模型的性能有着显著影响。适当的学习率设置对于实现高识别准确度至关重要,因为其决定了权重在梯度方向上的移动距离及每次梯度下降的步长。过高的学习率虽然可以加快网络在初期的收敛速度,但随着训练的深入,可能会导致网络出现振荡,从而无法达到最佳性能点。相反,过低的学习率则会导致收敛过慢,增加模型的训练时间。因此,一个有效的策略是在训练初期采用较高的学习率,随着梯度下降至某一临界值后逐渐降低学习率。这种逐步调整的方法有助于网络更精确地逼近最优解。

为了防止模型随着迭代次数增加而过拟合,本文还引入了 Dropout 和正则化技术。在实验中,通过使用不同的学习率进行训练并测量对应的识别准确率。结果表明,随着学习率的降低,模型的准确率逐渐提高。当学习率降至约 0.009 时,准确率达到峰值。继续降低学习率,准确率开始下降,这表明该学

习率附近的模型可能是最优的。上述这些发现为神经网络模型的学习率调整提供了重要的指导,有助于在保持高效训练的同时获得更高的识别性能。

2.3.1 图像检测评价指标

在进行图像检测表面缺陷多分类研究时,通常关注真正例、假正例和假反例这 3 种关键统计指标。其中,真正例 TP(true positive)是指实际上合格且被正确预测为合格的样本数量;假正例 FP(false positive)是指实际上合格但错误地预测为有缺陷的样本数量;假反例 FN(false negative)是指实际上有某种缺陷但被错误预测为合格的样本数量。基于这 3 种统计指标,相应地,本文采用精确率 P(precision)、召回率 R(recall)和 F1 分数(F1 score)这 3 种评价指标来评估分类性能。其中,准确率是评估分类效果最直观的指标,其反映了模型对整体数据分类正确性的比例^[9],其表达式为

$$A = \frac{TP}{TP+FP+FN} \quad (7)$$

而当不同类别的样本数量不平衡时,仅需将多数类样本预测正确即可获得更高的准确率,仅凭 1 个指标无法全面评价模型的分类性能。因此,引入精确率和召回率这 2 个指标,分别定义为

$$P = \frac{TP}{TP+FP} \quad (8)$$

$$R = \frac{TP}{TP+FN} \quad (9)$$

另外,F1 分数是精确率和召回率的调和平均值,即

$$F = \frac{2PR}{P+R} \quad (10)$$

在对数量不平衡数据进行实验结果评价时,应综合考虑上述 3 种评价指标的结果。

2.3.2 batch size 的对比与选择

批量大小在神经网络的训练和测试过程中扮演着重要角色,它定义了每个训练周期(epoch)中处理的图像数量。合适的 batch size 不仅可以提高模型的训练速度,还有助于提升识别精度。当 batch size 设置较小时,模型的收敛速度往往较慢且不稳定,同时损失值可能出现较大的波动。而设置过大

的 batch size 虽然可以增加每次训练的数据量,从而加快训练速度,但这同时也会增加计算量和内存消耗,有可能导致模型陷入局部最优解,从而影响最终的性能^[10]。

在实验过程中,通过设置不同的 batch size 来进行对比分析。表 3 为不同学习率下的识别结果,表 4 为不同 batch size 下的识别效果。表 3 和表 4 的实验数据显示,在训练周期设置为 30、batch size 设置为 16 时能够使模型获得最小的损失值,并在测试集上达到最高的准确率。这表明在本研究中,选择 16 作为 batch size 能够在确保模型稳定收敛的同时,最大程度地提高准确率,从而在效率和性能之间达到最佳平衡。

表 3 不同学习率下的识别结果

Tab. 3 Recognition results at different learning rates

学习率	训练损失	训练准确率/%	测试损失	测试准确率/%
0.006 0	7.562 1	88.93	16.120 0	75.43
0.003 0	2.246 7	91.63	5.117 1	88.72
0.001 0	0.004 3	99.84	2.247 8	97.42
0.000 9	0.039 8	100	0.388 9	98.43
0.000 5	0.043 6	99.43	0.983 9	96.98
0.000 3	0.685 5	97.82	4.298 3	93.37

表 4 不同批量大小下的识别结果

Tab. 4 Recognition results under different batch sizes

batch size	训练损失	训练准确率/%	测试损失	测试准确率/%
4	0.019 5	100	0.498 6	99.23
8	0.025 8	100	0.500 8	98.88
16	0.042 3	100	0.409 0	97.43
32	0.070 8	100	4.458 2	96.68
64	1.990 2	100	9.415 7	95.98

3 实验验证

3.1 实验对象及实验数据集


为验证改进后 VBE 板元件失效检测算法的准确性,对实验平台进行了搭建。图像数据集使用工业现场采集到的 VBE 板元件失效图像^[11],VBE 板图像如图 6 所示;对 VBE 板图像进行预处理,图

像灰度化处理结果如图 7 所示,图像二值化处理结果如图 8 所示;对图像去噪并使用 Canny 算子对图像进行锐化处理,结果如图 9 所示。



图 6 VBE 板图

Fig. 6 Photo of VBE board




(a)原始图像

(b)灰度图像

图 7 图像灰度化处理

Fig. 7 Image grayscale processing




(a)原始图像

(b)二值化图像

图 8 图像二值化处理

Fig. 8 Image binarization processing



(a)原始图像

(b)去噪后图像

图 9 图像去噪并使用 Canny 算子锐化处理

Fig. 9 Image denoising and implementing Canny operator for image sharpening

在开发基于深度学习的 SqueezeNet 模型初期,尤其是针对 VBE 设备故障检测的场景,有效利用现有的公开数据集构建训练基础是一个实用且高效的策略。公开数据集通常包含丰富的电子设备图像,通过筛选与调整,这些图像能够为特定

的 VBE 设备故障检测提供初步的数据支持。为了进一步提升模型在真实应用场景中的泛化能力,采用图像处理技术进行数据增强成为关键步骤。旋转、缩放、裁剪及噪声添加等技术不仅能人工增加数据集的多样性,还能模拟实际操作环境中可能遇到的各种变化,从而为模型训练注入更多的现实场景元素。

同时,准确的数据标注对于模型训练的成功至关重要。在这个过程中,高效且准确的标注工具 LabelImg 不仅能够加速大规模图像数据的标注过程,还能确保标注结果的一致性和准确性,为模型训练提供可靠的标签支持。

在深度学习项目中,确保数据的正确验证对于评估模型的性能至关重要。通常,数据集会被划分为训练集、验证集和测试集,比例大致为 70%、15%和 15%,这种划分策略有助于在独立的数据子集上进行模型训练和评估,以此避免过拟合问题,并准确地评估模型的泛化能力。特别是在数据量较小的情况下,采用 k -折交叉验证方法可以进一步增强评估的准确性和可靠性,即通过将数据集分成 k 个子集并轮流使用其中 1 个子集作为测试集,其余作为训练集,这一过程重复 k 次。此外,借助准确率、精确率、召回率和 F1 分数等多个性能指标,可以从多个维度全面评估模型的性能,揭示模型的优势和潜在弱点。这种综合性的验证流程为深度学习模型的开发和优化提供了坚实的评估基础,确保了模型在实际应用中能够达到预期的效果。

在 VBE 板元件失效检测的研究中,本文构建了 1 个包含不同故障类型(电容器老化、二极管故障、晶体管故障和焊点故障)及合格 VBE 板图像的原始数据集。由于故障图像在数量上与合格图像存在显著差异,因此本文采用了数据平衡策略,即对多数类的合格图像进行下采样,并通过图像处理技术对少数类的故障图像进行上采样,以平衡各类别间的样本数量。最终得到的平衡后数据集,既保持了与原始数据集相似的总图像数量,又实现了类别间的均衡,进一步划分为 70%训练集、

15%验证集和 15%测试集,可为高效地训练和评估元件失效检测模型奠定基础^[12]。

该 VBE 板表面图像的原始数据集 1 共有 4 000 张图像,由于生产线上各类缺陷 VBE 板的出现存在不确定性,获得的各类别 VBE 板图像的数量差别较大,其中合格 VBE 板图像 2 000 幅,电容器老化图像 800 幅,二极管故障图像 200 幅,晶体管故障图像 400 幅,焊点故障图像 600 幅。对原始数据集 1 内的图像数据进行数据平衡,以提高模型对于少数类样本的学习能力。根据各类别图像数量的差异大小,选择上采样和下采样结合的方式进行数据平衡^[13]。先对多数类样本进行下采样,即在合格 VBE 板图像中随机挑选 1 600 张,再对少数类(即各类缺陷 VBE 板)图像进行上采样,具体为:将电容器老化图像旋转 3 次得到 539 幅图像,则电容器老化图像扩充至 743 幅;从二极管故障图像中随机选取 50%的图像并旋转 1 次获得 306 幅图像,得到二极管故障图像共计 736 幅;将晶体管故障图像旋转 5 次获得 656 幅图像,则晶体管故障图像扩充至 765 幅。各少数类样本数量和多数类的合格 VBE 板样本数量保持基本一致,此时经过数据平衡的数据集 2 内共包含 3 882 幅图像,与原始数据集 1 的图像数量保持基本一致。

3.2 实验结果

使用数据集 1 对 AlexNet、VGGNet、MobileNet(一种轻量级网络)、SqueezeNet(另一种轻量级网络)和改进的 SqueezeNet 这 5 种深度学习模型进行了训练。所有模型在训练时采用了相同的参数设置,以确保比较的公平性,测试结果见表 5。可知,本文所提改进的 SqueezeNet 方法训练获得模型的准确率明显优于其他经典算法,准确率可达 95.27%,且模型大小满足轻量化要求。

为验证所提改进的 SqueezeNet 方法的效果,本文采用数据集 1 和经过平衡处理的数据集 2 分别进行了深度学习训练,并对比了标准 SqueezeNet 和改进的 SqueezeNet 的表现,结果见表 6。可见:使用数据集 1 时,2 种算法的准确率较其他 3 个评价指标分别高出约 3%~7%;而在使用平衡后的数据集 2

进行训练时,不仅 4 项评价指标的成绩普遍比数据集 1 提高了约 8%~14%,各项指标间的差距也控制在 0.5%以内,表明数据集 2 的使用显著提升了多分类训练的效果。此外,使用数据集 2 时,改进的 SqueezeNet 模型的单张图像平均推断时间约为 1.77 ms,与原始 SqueezeNet 模型相比,推断时间几乎未增加,这表明其能够满足工业流水线对高速自动化检测的需求。

表 5 各个算法的测试结果

Tab. 5 Test results of various algorithms

算法	准确率/%	模型大小/MB
AlexNet	84.27	230.00
VGGNet	87.36	100.00
MobileNet	88.08	39.00
SqueezeNet	90.82	4.70
改进的 SqueezeNet	95.27	4.77

表 6 不同模型的测试结果

Tab. 6 Test results of different models


数据集	模型	Top1 准确率/%	F1 分数/%	平均精确率/%	平均召回率/%	平均推断时间/ms
数据集 1	SqueezeNet	86.89	82.03	84.96	80.60	1.60
	改进的 SqueezeNet	88.86	85.05	84.68	85.98	1.82
数据集 2	SqueezeNet	93.76	93.77	93.80	93.70	1.70
	改进的 SqueezeNet	95.51	95.50	95.70	95.50	1.77

为评估改进的 SqueezeNet 方法在处理少数类样本上的表现,本文使用 2 种数据集训练了标准 SqueezeNet 和改进的 SqueezeNet。图 10 为不同模型的混淆矩阵,可见采用改进的 SqueezeNet 对数据集 2 进行训练时,各类别的预测准确率最高,尤其是在少数类别的识别上有显著提升,减少了误判。图 11 为不同模型的各类别测试结果,可见:使用数据集 1 训练的模型在各项评价指标上表现不一,对“二极管故障”和“焊点故障”这些少数类别的识别效果较差;然而,使用数据集 2 训练的改进的

SqueezeNet 模型不仅在精确率、召回率和 F1 分数上均超过 90%,且“晶体管故障”类别的 F1 分数由 86.80%(图 11(a))显著提高至 94.37%(图 11(d));尽管模型更注重整体准确率,导致某些评价指标如“焊点故障”类的分数略有降低,但改进的 SqueezeNet 在数据集 2 的应用显著提高了对少数

类图像的学习能力,优化了数据不平衡情况下的训练效果。


综上所述,本文通过使用不同的数据集和模型




(a)数据集 1 SqueezeNet 模型



(b)数据集 1 改进的 SqueezeNet 模型




(c)数据集 2 SqueezeNet 模型




(d)数据集 2 改进的 SqueezeNet 模型

图 10 不同模型的混淆矩阵


Fig. 10 Confusion matrices of different models




(a)数据集 1 SqueezeNet 模型



(b)数据集 1 改进的 SqueezeNet 模型



(c)数据集 2 SqueezeNet 模型



(d)数据集 2 改进的 SqueezeNet 模型

图 11 不同模型各类别测试结果

Fig. 11 Category-wise test results of different models

进行了一系列实验。首先,使用数据集 1(未平衡数据集)和数据集 2(经过平衡处理的数据集)进行了训练,测试了标准 SqueezeNet 和改进的 SqueezeNet 模型。实验结果显示,无论是使用数据集 1 还是数据集 2,改进的 SqueezeNet 模型均表现出了较高的准确率。数据平衡处理显著提高了模型的性能,通过对少数类样本进行上采样,使得模型能够更好地学习到这些类别的特征,从而提高了整体的识别准确率。改进的 SqueezeNet 模型在数据集 1 和数据集 2 上均表现出较高的准确率,特别是在数据集 2 上的性能更为突出。这是因为模型结构的改进,引入的深度可分离卷积和残差连接增强了模型的特征提取能力和泛化能力。改进的 SqueezeNet 模型在少数类样本的识别上表现出显著的提升,这对于实际应用中的类别不平衡问题具有重要意义。

此外,通过定量指标和定性结果可以看出,基于改进的 SqueezeNet 的方法能够实现对 VBE 板元件失效的高效、准确的自动检测识别,能够满足生产线质量控制的需求,验证了所提方法的有效性。

4 结论

本文针对阀基电子设备电路板(VBE 板)元件失效检测的准确性和效率问题,开展了深度学习模型的应用研究。首先,采用了改进的 SqueezeNet 模型,引入深度可分离卷积和残差连接,显著提升了元件失效识别的准确率,减少了 30%的计算资源消耗,并将误差率降低到原来的 1/2 以下。进一步针对实时处理需求,通过引入残差连接优化了模型的计算效率,实现了在标准测试集上将元件失效检测时间缩短 30%,同时保持了高达 95%的准确率。这些改进不仅提升了 VBE 板元件失效检测的性能,也为类似的工业应用提供了可行的深度学习解决方案。

在实际电力系统中,将改进的 SqueezeNet 方法应用于 VBE 设备故障检测,具有高度的可行性,尤其是考虑到其在准确性和计算效率上的优势。然而,要成功部署此模型,需克服实时性需求、高质量

数据获取难题、模型泛化能力及与现有系统的集成兼容性等挑战。采用先进的数据增强技术并利用迁移学习来提升模型对新故障类型的适应能力,增强模型的可解释性以提高操作员信任,以及建立灵活的模型更新机制来应对设备和系统的变化,这些策略的综合应用将为实现改进 SqueezeNet 在电力系统中的应用提供坚实的基础。

参考文献:

- [1] Christian H J, Blakeslee R J, Boccippio D J, et al. Global frequency and distribution of lightning as observed from space by the optical transient detector [J]. *Journal of Geophysical Research(Atmospheres)*, 2003, 108(D1): 4005.
- [2] Colomina I, Molina P. Unmanned aerial systems for photogrammetry and remote sensing: A review [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 92: 79-97.
- [3] Moran M S, Inoue Y, Barnes E M. Opportunities and limitations for image-based remote sensing in precision crop management [J]. *Remote Sensing of Environment*, 1997, 61(3): 319-346.
- [4] Liu Changan, Chen Zhongxin, Shao Yun, et al. Research advances of SAR remote sensing for agriculture applications: A review [J]. *Journal of Integrative Agriculture*, 2019, 18(3): 506-525.
- [5] Gens R. Oceanographic applications of SAR remote sensing [J]. *GIScience & Remote Sensing*, 2008, 45(3): 275-305.
- [6] Pohl C, van Genderen J L. Review article Multisensor image fusion in remote sensing: Concepts, methods and applications [J]. *International Journal of Remote Sensing*, 1998, 19(5): 823-854.
- [7] Wang Zhen, Guo Jianxin, Zhang Chuanlei, et al. Multi-scale feature enhancement network for salient object detection in optical remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5634819.
- [8] Ghimire P, Lei Deng, Juan Nie. Effect of image fusion on vegetation index quality—A comparative study from Gaofen-1, Gaofen-2, Gaofen-4, landsat-8 OLI and MODIS imagery [J]. *Remote Sensing*, 2020, 12(10): 1550.
- [9] Sánchez A V D. Advanced support vector machines and kernel methods [J]. *Neurocomputing*, 2003, 55(1-2): 5-20.

[10] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C]// 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego, CA, USA, 2005: 886-893.

[11] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.

[12] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features [C]// Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR. Kauai, HI, USA, 2001: 1.

[13] 李鹏. 黄河口及其邻近海域悬浮泥沙多尺度时空动态与驱动机制[D]. 上海: 华东师范大学, 2023.

Li Peng. Multi-scale spatiotemporal dynamics and driving mechanisms of suspended sediment in the Yellow River Estuary and its adjacent seas [D]. Shanghai: East China Normal University, 2023.



刘隆晨

作者简介:

刘隆晨(1987-),男,通信作者,博士研究生,高级工程师。研究方向:高压直流输电及换流阀检测试验技术。E-mail: liulongchen@live.cn。


杨玥坪(1995-),男,硕士研究生,工程师。研究方向:柔性直流输电技术。E-mail: yangyp0018@sc.sgcc.com.cn。

贾志杰(1984-),男,硕士研究生,高级工程师。研究方向:高压直流输电技术。E-mail: jiazj 1854@sc.sgcc.com.cn。

黄宇(1985-),男,硕士研究生,高级工程师。研究方向:换流阀及阀控运维技术。E-mail: huangy0033c@sc.sgcc.com.cn。

唐世雄(1990-),男,本科,工程师。研究方向:直流输电工程运维技术。E-mail: tangsx3354@sc.sgcc.com.cn。

谭博洋(1992-),男,本科,工程师。研究方向:直流输电一次设备运检技术。E-mail: tanby001x@sc.sgcc.com.cn。



来源:天津文明网