

基于改进 ResNet34 网络的变电站设备巡检 图像分类识别的方法

刘志坚, 孟欣雨, 刘航*, 罗灵琳, 张德春
(昆明理工大学 电力工程学院, 云南 昆明 650500)

Method for Substation Equipment Inspection Image Classification and Recognition Based on Improved ResNet34 Network

LIU Zhijian, MENG Xinyu, LIU Hang*, LUO Linglin, ZHANG Dechun
(Faculty of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China)

Abstract: Aiming at the problems of limited image scale and low recognition accuracy in the field of substation equipment inspection image recognition, an image classification and recognition method based on improved ResNet34 network is proposed. The Seam Carving algorithm is employed to compress the low-energy areas in the image for the preservation of key features. Additionally, six types of image enhancement techniques such as elastic transformation and Gaussian noise are utilized to increase the diversity of the images. The basic ResNet34 network is integrated with the convolutional block attention module to enhance the model's ability to extract key features from equipment inspection images. A model pre-trained on the ImageNet dataset is utilized as a feature extractor for transfer learning to address the issue of insufficient sample quantity. A cosine annealing strategy is introduced in the Adam optimizer to dynamically adjust the learning rate, to make the improved ResNet34 network converge to the optimal solution faster. Experimental results show that the proposed method improves accuracy by 0.073 3 and reduces the loss rate by 0.201 9 compared to the basic ResNet34 network, which provides a reliable solution for the field of substation equipment inspection image recognition.

Key words: ResNet34; convolutional block attention

基金项目: 云南省重点研发计划(202303AA080002); 云南省基础研究重点项目(202301AS070055); 云南省基础研究青年项目(202201AU070086)

Major Project of Basic Research Foundation of Yunnan Province (202303AA080002); Key Project of Yunnan Fundamental Research Projects (202301AS070055); Youth Project of Yunnan Fundamental Research Projects (202201AU070086)

module; transfer learning; cosine annealing strategy

摘要: 针对变电站设备巡检图像识别领域中存在的图像规模有限和识别准确率低等问题,提出了一种基于改进 ResNet34 网络的图像分类识别方法。采用 Seam Carving 算法对图像中的低能量区域进行压缩以保留关键特征;同时使用弹性变换、高斯噪声等 6 种图像增强技术来增强图像的多样性。将基础 ResNet34 网络与卷积注意力模块结合,增强模型对设备巡检图像关键特征的提取能力。使用在 ImageNet 数据集上的预训练模型作为迁移学习的特征提取器来解决样本数量不足的问题。在 Adam 优化器中引入余弦退火策略来动态调整学习率使改进的 ResNet34 网络更快收敛至最优解。试验结果表明所提方法比基础 ResNet34 网络的准确率提升了 0.073 3, 损失率降低了 0.201 9, 为变电站设备巡检图像识别领域提供了一种可靠的解决方案。

关键词: ResNet34; 卷积注意力模块; 迁移学习; 余弦退火策略

0 引言

输变电设备的安全稳定运行对于保证电力供应的连续性至关重要,而变电站设备的健康监测是实现这一目标的关键环节^[1]。近年来,变电站设备巡检图像识别技术已成为一种有效的监测手段,其不仅能够在故障发生前提供预警,还有助于防止潜在的设备故障。但是这种技术在实际应用中面临着一系列挑战,包括关键特征提取困难、图像识别准确率低以及设备巡检图像样本数量偏少等^[2]。这些挑战限制了传统分类识别模型在性能

和准确度方面的提升。

在变电站设备巡检图像识别领域,传统方法在早期起到了重要的作用。例如,文献[3]提出了一种集成模态分解的方法,通过提取故障电流的暂态高频分量实现了对样本的分类。文献[4]提出了一种基于小波变换的电网复合扰动信号分类识别方法,为电网质量的智能化管理提供了理论支持。文献[5]使用基于图像检索算法对特征向量直方图进行分类,实现了对自然光和红外电气设备图像的分类。文献[6]提出了一种基于颜色空间变量的输电线图像分类的处理技术,提高了输电线图像的分类和识别能力。但是传统方法主要存在两个问题:(1)在复杂环境中准确性受限;(2)泛化能力不足,难以有效处理不同环境下的样本。随着深度学习技术的兴起,基于此技术的方法在处理复杂场景中显示出更强大、更灵活的性能。

深度学习通过对神经元接收的多样输入进行精细的权重处理来实现分类,这一过程赋予了其卓越的泛化能力和显著的关键特征提取优势。例如,文献[7]通过研究红外测温图像分类识别方法,提出了一种基于改进 MobileNetV2 的电力设备红外图像分类识别模型,为电力设备智能巡检提供了解决方案。文献[8]提出了一种基于深度残差网络的电缆绝缘层截面图像分类方法,通过对不同形状的电缆绝缘层图像进行深层特征分析和多级分类,实现了电缆全自动检测的需求。文献[9]提出了一种结合深度学习和支持向量机(Support Vector Machine,SVM)的图像分类模型,通过对原始数据进行扩充、改进卷积神经网络(Convolutional Neural Network,CNN)并利用 SVM 进行分类测试,实现了对样本图像的分类。尽管深度学习模型在该领域应用广泛,但在处理大规模及复杂环境下的图像数据时,存在两个主要问题:(1)数据集样本数量不足;(2)巡检图像背景复杂难以提取特征,图像分类识别效果不佳。

针对上述问题,本文提出了一种基于改进 ResNet34 网络的变电站设备巡检图像分类识别方法。该方法首先通过图像接缝裁剪(Seam Carving,SC)算法对设备巡检图像背景中的无效低能量区域进行压缩;再通过六种传统图像增强技术提高图像的多样性;在此基础上,引入了卷积

注意力模块(Convolutional Block Attention Module,CBAM)增强模型对设备巡检图像重要特征的提取能力,并通过迁移学习策略解决巡检数据集样本数量不足的问题,以及通过在 Adam 优化器中引入余弦退火策略进行学习率的动态调整;最后,通过消融试验验证了所提方法在变电站设备巡检图像识别任务中的性能。

1 变电站设备巡检图像预处理方法

1.1 图像低能量区域压缩方法

为了解决变电站设备巡检图像在复杂环境下的特征提取难题,本文引入了 SC 算法。SC 算法能够在不改变图像主要内容的情况下,调整图像尺寸,从而突出设备的关键特征,提升巡检图像分类识别的效果。通过识别图像中的低能量区域并将其移除,SC 算法可以更准确地捕捉到巡检图像中的重要信息,为后续的图像处理和分类识别奠定了基础。具体步骤如下^[10]:

(1) 能量计算:在 SC 算法中,应用 Sobel 滤波器计算出图像每个像素点的水平和垂直方向的梯度幅度,以此来确定其能量值。这一计算过程涵盖了梯度的两个关键分量,从而有效识别图像中的低能量区域。水平梯度 \mathbf{G}_x 、垂直梯度 \mathbf{G}_y 以及能量 $E(\mathbf{I})$ 的计算式如式(1)~式(3)所示:

$$\mathbf{G}_x = \text{Sobel}_x(\mathbf{I}) \quad (1)$$

$$\mathbf{G}_y = \text{Sobel}_y(\mathbf{I}) \quad (2)$$

$$E(\mathbf{I}) = \sqrt{\|\mathbf{G}_x\|^2 + \|\mathbf{G}_y\|^2} \quad (3)$$

式中: \mathbf{G}_x 和 \mathbf{G}_y 分别为通过 Sobel 滤波器在水平和垂直方向上计算的梯度; \mathbf{I} 为设备巡检图像; $E(\mathbf{I})$ 为巡检图像 \mathbf{I} 的能量。

(2) 动态规划寻找最小能量缝隙:使用动态规划方法定义 S 矩阵来找到最小能量的缝隙。这一过程在调整图像大小的同时,最大限度地保留了图像的核心特征,尤其有助于突出图像像素变化较为剧烈的边缘,如式(4)所示:

$$S[i, j] = E[i, j] + \min(S[i - 1, j], S[i, j - 1], S[i - 1, j - 1]) \quad (4)$$

式中: $S[i, j]$ 为第 i 行第 j 列像素的累积能量; $E[i, j]$ 为第 i 行第 j 列像素的能量。

(3) 提取并移除能量缝隙:利用动态规划寻找最小能量缝隙,再通过移除缝隙中的像素来改变巡检图像的大小,以保留巡检图像的核心特征。

本文以变电站设备巡检红外图像和可见光绝缘子图像为例展示使用 SC 算法对图像的处理效果,如图 1 所示。

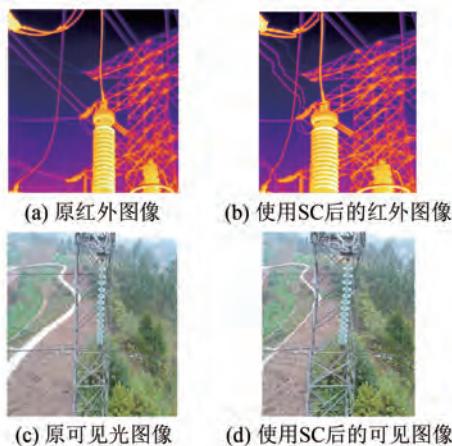


图 1 使用 SC 算法前后的红外和可见光图像对比

Fig. 1 Comparison of infrared and visible light images before and after using SC algorithm

可以明显观察到图 1(a) 和图 1(c) 中左侧部分缺乏明确的目标区域,通过使用 SC 算法动态搜索能量最小的缝隙,对图像进行精细处理后,得到了图 1(b) 和图 1(d) 所示的图像。

由上述分析可知,SC 算法可同时应用于红外图像和可见光图像,具有良好的通用性。

1.2 变电站设备巡检图像增强方法

在应用 SC 算法调整变电站设备巡检图像尺寸并保留关键特征后,针对图像复杂性、样本数量不足等问题,本文以橡胶绝缘子图像为例,采取了 6 种传统图像增强技术进一步提升图像的多样性^[11],具体如图 2 所示。

(1) 图像裁剪技术:如图 2(a) 所示,使用图像裁剪技术后巡检图像中的目标被更加突出地显示,有效减少了背景干扰和无关信息的影响。

(2) 对比度增强技术:如图 2(b) 所示,通过增强对比度,巡检图像上的细节更加清晰可见,解决了原始图像中对比度不足的问题。

(3) 弹性变换技术:如图 2(c) 所示,通过弹性变换技术来适应巡检图像在实际场景中的各种姿态和形态变化,提高了模型对图像形态变化的适应性和鲁棒性。

(4) 拼图变换技术:如图 2(d) 所示,通过拼图变换模拟巡检图像在实际环境中可能面临的复杂情况,从而提高模型对不同场景的泛化能力。

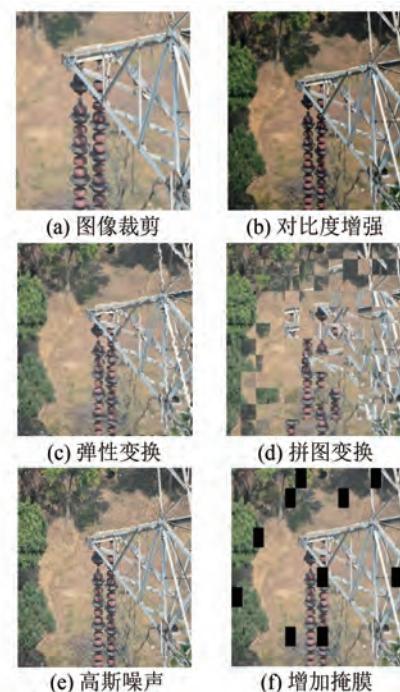


图 2 使用 6 种图像增强技术的对比图像

Fig. 2 Comparison images of using 6 image enhancement techniques

(5) 引入高斯噪声技术:如图 2(e) 所示,引入高斯噪声模拟真实环境中巡检图像可能存在的噪声干扰,使得训练模型能够在噪声环境中保持良好的识别性能。

(6) 增加掩膜技术:如图 2(f) 所示,通过增加掩膜模拟受物体遮挡的情况,更好地处理巡检图像中的目标部分被遮挡或模糊的情况。

本文通过实施一系列图像增强技术,将 503 张原始图像扩展至 3 018 张。为验证基于改进 ResNet34 网络的分类识别方法奠定了良好的数据基础。

2 基于改进 Resnet34 的分类网络构建

2.1 改进的 Resnet34 网络结构

ResNet34 作为一种深度卷积神经网络^[12-13],通过引入残差块和跳跃连接,有效缓解了深度神经网络中梯度消失的问题。然而,针对变电站设备巡检图像所呈现的复杂红外和可见光信息以及对空间尺度变化的鲁棒性需求,原始的 ResNet34 网络具有一定的局限性。

为了克服这些局限性,本文对 ResNet34 进行了一系列优化调整,使其更适合设备巡检图像分

类的具体需求。变电站设备巡检图像的复杂性要求模型能够有效处理各种级别的特征,从基本的纹理和形状到高级的模式和结构信息。如图 3 所示,改进的 ResNet34 网络结构包含如下 4 个主要部分:

(1) 特征注意力机制模块:在模型中加入了 CBAM,可以使模型更有效地提取变电站设备图像中的低级和高级特征,包括设备的颜色、形状、组件间的关系以及可能的故障标志等。

(2) 最大池化下采样层:经过处理的特征图传入一个 3×3 的最大池化下采样层。这一步骤的目的是在保留重要信息的同时减少计算复杂度,提高模型的计算效率。

(3) 四个堆叠的残差块:残差块的设计允许网络学习输入和输出之间恒等映射,增强了训练过程中信息的流动,可以更好地解决深层网络梯度消失和爆炸等问题。

(4) 自适应平均池化层:特征图被送入平均池化层中,使用自适应下采样技术将特征图转化为 1×1 的特征矩阵。此步骤可以减少模型参数数量,降低过拟合风险,同时提高对不同尺寸输入图像的适应性。

2.2 CBAM 注意力机制

CBAM 注意力机制通过自动聚焦图像中的关键区域,能够从中提取出对分类任务至关重要的特征^[14]。此机制独特地结合了空间和通道两个维度的特征,不仅显著提升了模型的整体性能,还

优化了计算资源的使用效率。如图 4 所示,CBAM 注意力机制网络可以分为如下三个部分:

(1) 通道注意力:对输入特征图实施全局平均池化和全局最大池化操作,这两个操作将特征图在通道维度上进行压缩,以获得全局特征的通道描述符;然后,通过共享权重的多层感知机 (Multilayer Perceptron, MLP) 处理这些描述符,从而获得通道注意力特征图,如式(5)所示:

$$\mathbf{M}_c = \text{Sig} \{ \text{MLP} [\text{AvgPool} (\mathbf{X}) + \text{MaxPool} (\mathbf{X})] \} \quad (5)$$

式中: \mathbf{M}_c 为通道注意力特征图; \mathbf{X} 为输入特征图; MLP 为多层感知机函数; AvgPool 为全局平均池化操作; MaxPool 为全局最大池化操作; Sig 为 Sigmoid 激活函数。

(2) 空间注意力:输入特征图被送入空间注意力机制网络;通过全局平均池化和最大池化获得空间注意力特征图;然后,通过卷积操作将这两个注意力图融合,如式(6)所示:

$$\mathbf{M}_s = \text{Sig} \{ \text{Conv} [\text{AvgPool} (\mathbf{X}), \text{MaxPool} (\mathbf{X})] \} \quad (6)$$

式中: \mathbf{M}_s 为空间注意力特征图; Conv 为卷积操作。

(3) 特征的加权:在 CBAM 机制中,将空间注意力权重和通道注意力权重进行乘法操作来实现对输入特征图的特征加权,最终得到输出特征图,如式(7)所示:

$$\mathbf{X}' = (\mathbf{X} \otimes \mathbf{M}_c) \otimes \mathbf{M}_s \quad (7)$$

式中: \mathbf{X}' 为输出特征图; \otimes 为乘法操作。

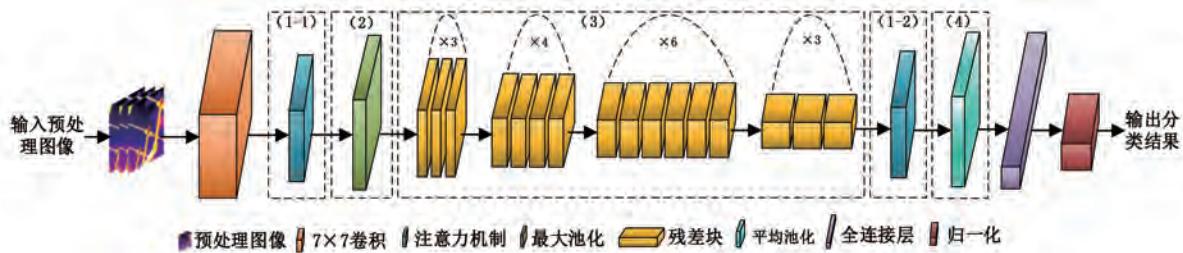


图 3 改进的 Resnet34 网络结构

Fig. 3 Improved ResNet34 network structure

2.3 迁移学习以及优化器的引入

2.3.1 迁移学习策略

为了有效解决变电站设备巡检红外图像和可见光图像样本数量有限以及样本质量不佳的问题,引入了迁移学习策略。迁移学习是一种利用在一个任务上预训练好的模型来解决另一个相关

任务的方法^[15-16]。本文选择了在 ImageNet 数据集上预训练的 ResNet34 网络模型作为特征提取器,该策略的执行步骤如下:

(1) 导入预训练模型:将 ImageNet 数据集中学习到的预训练权重加载到 ResNet34 模型中,来加速图像识别模型的训练过程;由于 ImageNet 数

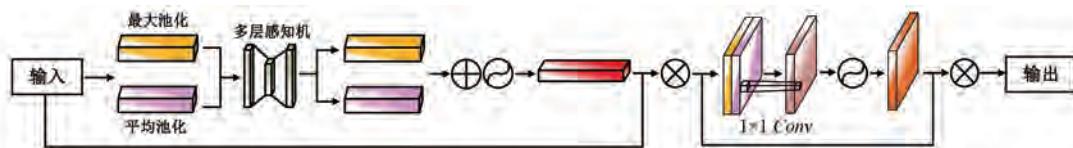


图 4 CBAM 注意力机制网络

Fig. 4 CBAM attention mechanism network

据集上预训练的模型已经学习到了通用的图像特征,因此模型已具备良好的泛化能力,加载到 ResNet34 模型的预训练权重 W_p 的表达式为

$$W_p = \text{LoadWeights}(\text{R_ResNet34}) \quad (8)$$

式中: R _ ResNet34 为改进的 ResNet34 网络, LoadWeights 为加载权重。

(2) 适应性调整:对预训练的 ResNet34 模型进行适应性调整,使网络能更好地适应设备巡检图像识别任务;再通过修改全连接层的输出节点数,将模型的输出与巡检图像的 5 种类别相匹配。这种调整既保留了模型在通用图像数据上学习到的特征,又使模型专门适用于变电站设备巡检图像识别任务,调整后的模型权重 W_a 的表达式为

$$W_a = \text{AdaptLayer}(W_p, \text{target_classes}) \quad (9)$$

式中: target _ classes 为目标任务的类别数量; AdaptLayer 为对模型进行适应性调整的函数。

(3) 特征融合策略:为处理电气设备的红外图像和可见光图像,采用特征融合方法将这两种不同类型的图像信息结合起来。这种策略不仅能够捕获更复杂、更丰富的信息,还能提高分类的准确性和鲁棒性。特征融合策略的实现如式(10)所示:

$$\mathbf{F}_{\text{fused}} = \alpha \cdot \mathbf{F}_{\text{infrared}} + (1 - \alpha) \cdot \mathbf{F}_{\text{visible}} \quad (10)$$

式中: α 为特征融合的权重系数,是一个可调参数; $\mathbf{F}_{\text{fused}}$ 为融合后的特征; $\mathbf{F}_{\text{infrared}}$ 为红外图像的特征; $\mathbf{F}_{\text{visible}}$ 为可见光图像的特征。

2.3.2 优化器的改进

为了优化并改进 Resnet34 网络的训练流程,在 Adam 优化器中引入余弦退火策略来动态调整学习率^[17-19]。余弦退火^[20]作为一种学习率调度策略,通过在训练过程中灵活调整学习率,来促使网络更迅速地收敛至最优解。

在每个训练周期内,余弦退火策略实现了“先降低再提升”的学习率调整模式。在训练的初期,学习率逐渐降低,有助于模型迅速适应设备巡检图像的复杂性并快速收敛;在训练的后期,学

习率逐步提升,使得模型更接近全局最优解。这种动态调整方式不仅可以避免陷入局部最优解还能提升模型的性能,学习率动态调整过程如式(11)所示:

$$\eta_t = \eta_{\min} + 0.5(\eta_{\max} - \eta_{\min})[1 + \cos(\pi T_{\text{cur}} / T_{\max})] \quad (11)$$

式中: η_t 为 t 时刻的学习率; η_{\min} 和 η_{\max} 分别为学习率的最小值和最大值; T_{cur} 为当前的训练步骤数或周期; T_{\max} 为每个周期的训练步骤数最大值。

本文选择 Adam 优化器而非传统的随机梯度下降优化器^[18],是因为 Adam 优化器具备自适应学习率调整能力,可以更好地适应不同任务和数据集;采用余弦函数的方式而非指数或线性衰减模式来调整学习率,是因为余弦函数可以更精细地控制学习率变化,并保证训练过程的平滑和稳定性。

3 试验及结果分析

3.1 试验环境及参数

试验采用的计算机为 DESKTOP-EMASPBQ, 并配备 AMD Ryzen 9-5900X 12-Core 处理器。所有编程和模型训练均基于 Python 编程语言,通过 PyTorch 框架实现。试验采用的数据集来源于网络开源数据和某电力公司,包含变电站设备的红外图像和可见光图像,共计 3 018 张。具体数据种类如表 1 所示。

表 1 数据集的构成

Tab. 1 Composition of the dataset

数据集种类	训练集	测试集
隔离开关 BI	509	127
电流互感器 CT	461	115
电压互感器 PT	538	134
橡胶绝缘子 RI	413	103
玻璃绝缘子 SQ	495	123

对试验所需的所有巡检图像首先进行图像预处理,然后统一裁剪为 240×240 像素的尺寸。模

型训练的初始学习率设置为 0.001。为了有效控制学习过程,选择融入余弦退火策略的 Adam 优化器来动态调整学习率。整个模型训练周期设定为 300 轮,并设定每 100 轮调整一次学习率以获得最佳性能。

3.2 消融试验及对比试验

3.2.1 图像预处理与增强试验

试验 1:作为基准试验,使用未经任何处理的 503 张巡检原始图像,并应用标准 ResNet34 网络模型进行图像分类。这一试验旨在评估模型在原始图像数据上的基本性能。从试验结果来看,模型在原始图像上的验证集损失率为 0.350 6,准确率为 0.864 6,为后续试验提供了基线性能指标^[21-22]。

试验 2:考虑到 SC 算法在压缩图像中的低能量区域方面的有效性,本试验对相同的图像集合应用了该技术。通过使用 SC 算法,图像中的关键信息得以更好地保留,同时剔除了图像背景中无关的低能量区域。使用 SC 处理后的图像在 ResNet34 网络上的训练结果表明,模型的性能有所提升,验证集损失率降至 0.327 4,准确率提高至 0.882 1。

试验 3:为了进一步提升模型的性能,在 SC 算法的基础上引入了六种传统图像增强技术,包括图像裁剪、对比度增强和弹性变换等。这些技术旨在模拟实际环境中可能遇到的多样化情况,从而提高模型的适应性和鲁棒性。试验结果显示,这些图像增强手段进一步提高了模型性能,验证集损失率降至 0.283 8,准确率提高至 0.903 9。试验 1~试验 3 的结果如表 2、图 5 和图 6 所示。

表 2 图像预处理与增强试验评价指标

Tab. 2 Evaluation indicators for image preprocessing and enhancement tests

试验	模型	训练损失率	训练准确率
试验 1	基准模型	0.350 6	0.864 6
试验 2	SC 模型	0.327 4	0.882 1
试验 3	SC+增强模型	0.283 8	0.903 9

试验 1~试验 3 结果表明,原始图像虽然提供了性能基线标准,但应用 SC 算法及其他图像增强技术后模型性能得到显著提升;SC 能够有效提升模型的准确性;结合 SC 和多种图像增强手段,可显著提高模型的鲁棒性和分类精度。

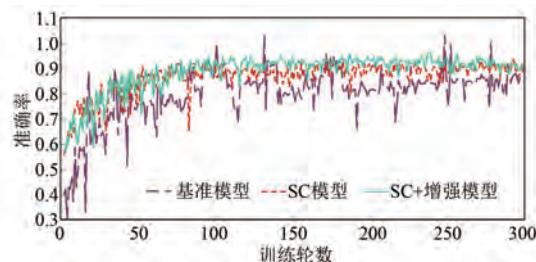


图 5 图像预处理与增强试验的准确率

Fig. 5 Accuracy of image preprocessing and enhancement tests

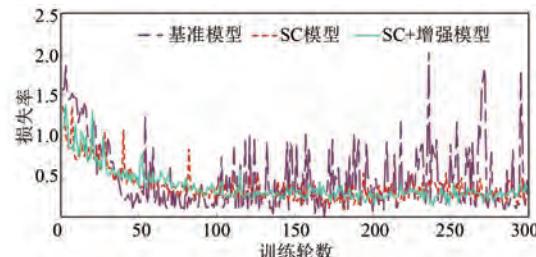


图 6 图像预处理试验的损失率

Fig. 6 Loss rate of image preprocessing and enhancement tests

3.2.2 改进的 ResNet34 图像分类网络试验

试验 4:在标准 ResNet34 网络中加入两个 CBAM。其中,一个模块被放置在网络的第一个卷积层后以有效捕获图像中的低级特征,如颜色、纹理和形状等。另一个模块被置于网络的后续部分,进一步提取图像的高级特征,如部件间的空间关系和潜在故障标记。这种双重注意力机制显著提升了模型的识别能力,验证集准确率达到 0.925 8,损失率为 0.279 4。

试验 5:采用在 ImageNet 数据集上预训练的 ResNet34 作为特征提取器,并对其进行微调以更好地适应巡检图像的特征。这种结合预训练和微调的策略不仅加快了模型的训练速度,还显著提高了模型在设备巡检图像识别任务上的性能,验证集准确率提升至 0.958 5,损失降至 0.143 4。

试验 6:在 ResNet34 的 Adam 优化器中引入余弦退火策略,促使模型快速收敛,并避免陷入局部最优解。通过学习率动态调整,模型训练过程更加稳定,进一步提升了模型的性能,验证集准确率提升至 0.960 2,损失降至 0.167 9。

试验 7:综合应用了前三个试验中的所有策略,即 CBAM 注意力机制、迁移学习以及余弦退

火策略。试验结果验证了这些策略共同作用下的效果。结合这些策略后,模型在电气设备图像识别任务上表现出最佳性能,验证集损失降至 0.081 9,准确率提升至 0.977 2。试验 4~试验 7 的结果如表 3、图 7 和图 8 所示。

表 3 改进的 ResNet34 图像分类网络试验评价指标

Tab. 3 Evaluation indicators for improved ResNet34 image classification network tests

试验	模型	训练损失率	训练准确率
试验 4	CBAM 模型	0.279 4	0.925 8
试验 5	迁移学习模型	0.143 4	0.958 5
试验 6	余弦退火模型	0.167 9	0.960 2
试验 7	本文模型	0.081 9	0.977 2

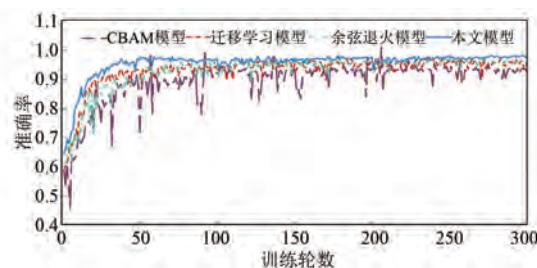


图 7 改进的 Resnet34 图像分类网络试验的准确率

Fig. 7 Accuracy of improved ResNet34 image classification network tests

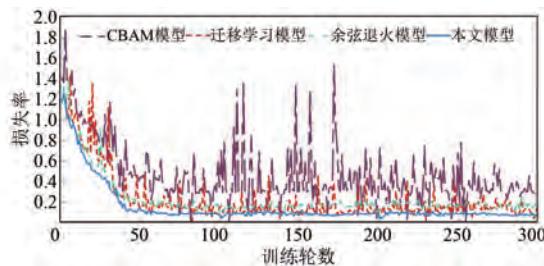


图 8 改进的 Resnet34 图像分类网络试验的损失率

Fig. 8 Loss rate of improved ResNet34 image classification network tests

通过试验 4~试验 7 深入探讨了不同策略对 ResNet34 网络在变电站设备巡检图像识别任务上的影响。试验结果表明,CBAM 注意力机制的引入显著提高了模型对图像特征的捕获能力;迁移学习策略进一步提升了模型的性能;余弦退火策略有效优化了模型的训练过程。结合这些策略的本文模型表现出最佳性能,突显了多种技术策略联合应用在复杂图像处理任务中的巨大潜力。

3.2.3 图像分类对比试验

试验 8:本试验采用了基于 AlexNet 的变电站

设备巡检图像识别分类模型^[23]。在此试验中,所有巡检图像经过 SC 算法以及图像增强的预处理技术,最终用于训练 AlexNet 网络模型。此试验的目的是评估在经过预处理和增强技术后,AlexNet 模型在变电站设备巡检图像识别任务中的性能。

试验 9:本试验使用基于 GoogLeNet 的变电站设备巡检图像识别模型^[24]。与试验 8 类似,所有巡检图像首先经过 SC 算法以及图像增强的预处理技术,最终用于训练 GoogLeNet 模型。此试验的目的是比较 GoogLeNet 与 AlexNet 模型在变电站设备巡检图像识别任务上的性能差异。

试验 10:本试验使用了基于 VGGNet 的变电站设备巡检图像识别模型^[25]。与试验 8 和试验 9 类似,将经过 SC 算法和图像增强处理的巡检图像用于训练 VGGNet 模型。此试验的目的是进一步探究不同深度学习模型在巡检图像识别任务上的性能,并与 AlexNet 和 GoogLeNet 模型进行比较。试验 8~试验 10 的结果如表 4、图 9 和图 10 所示。

表 4 图像分类对比试验评价指标

Tab. 4 Evaluation indicators for image classification comparative tests

试验	模型	训练损失率	训练准确率
试验 8	AlexNet 模型	4.164 5	0.537 1
试验 9	GoogLeNet 模型	0.413 6	0.875 2
试验 10	VGGNet 模型	1.355 1	0.841 6

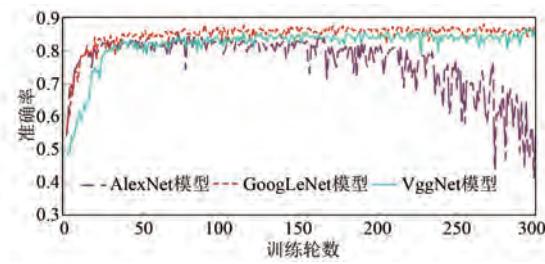


图 9 图像分类对比试验的准确率

Fig. 9 Accuracy of image classification comparative tests

进一步,使用混淆矩阵将本文模型与 AlexNet、GoogLeNet 和 VGGNet 模型得到的试验结果进行对比,如图 11 所示。

通过一系列试验,深入研究了不同图像识别方法和预处理技术对于变电站设备巡检图像分类识别任务的影响。结果表明,试验 7 采用的综合

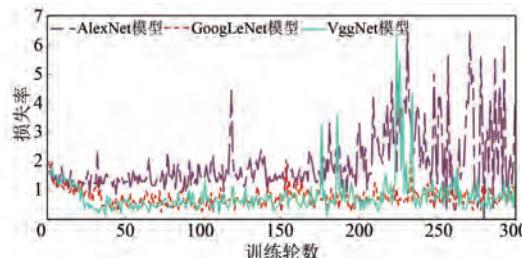


图 10 图像分类对比试验的损失率

Fig. 10 Loss rate of image classification comparative tests

策略在设备巡检图像识别任务中表现最佳,模型在验证集上的损失降至 0.081 9,准确率提升至 0.977 2,表明 CBAM 注意力机制、迁移学习和余弦退火策略的结合使模型更适应复杂的巡检图像数据,并显著提高了识别准确率;试验 8~试验 10 的对比试验,进一步揭示了不同深度学习模型在变电站设备巡检图像识别任务中的适应性和潜在差异。

4 结语

本文针对变电站设备巡检图像识别分类中存在的图像特征提取困难和样本数量较少等问题,提出了一种基于改进 ResNet34 网络的图像分类识别方法。通过一系列试验分析,得到如下结论:

(1) SC 算法能够有效提升模型的准确性,6 种图像增强技术能增加图像的多样性同时解决样本不足的问题;

(2) 对 ResNet34 网络进行改进,引入 CBAM 注意力机制成功地提取了图像中的关键信息,并增强了模型的识别精确度。采用迁移学习策略,利用在 ImageNet 数据集上预训练的模型参数,显著提高了模型的开发效率和性能;

(3) 在 Adam 优化器中引入了余弦退火策略,实现了学习率的动态调整,促进模型快速收敛。试验结果表明本文所提方法比基础 ResNet34 网络的准确率提升了 0.073 3,损失率降低了 0.201 9,为变电站设备巡检图像识别领域提供了一种可靠的解决方案。

参考文献

- [1] 韩欣. 基于机器学习的舰船电气设备寿命自动检测[J]. 舰船科学技术, 2021, 43(8): 193-195.

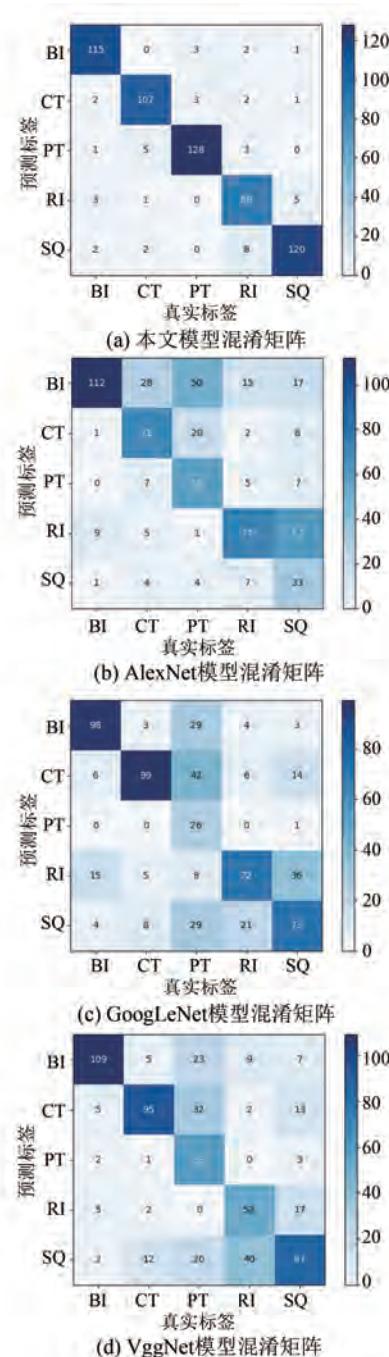


图 11 图像分类对比试验的混淆矩阵

Fig. 11 Confusion matrix of image classification comparative tests

HAN X. Automatic life test of marine electrical equipment based on machine learning [J]. Ship Science and Technology, 2021, 43(8): 193-195.

[2] 党晓婧, 刘顺桂, 朱光南, 等. 基于特征提取的电气设备红外图像识别算法[J]. 沈阳工业大学学报, 2023, 45(3): 264-269.

DANG X J, LIU S G, ZHU G N, et al. Infrared

- image recognition algorithm based on feature extraction for electrical equipment [J]. Journal of Shenyang University of Technology, 2023, 45(3): 264-269.
- [3] 刘树鑫, 卓裕, 李津, 等. 基于随机森林算法的配电线路短路故障分类[J]. 电器与能效管理技术, 2020, 8: 52-57.
- LIU S X, ZHUO Y, LI J, et al. Classification of short circuit faults in distribution lines based on random forest algorithm [J]. Low Voltage Apparatus, 2020, 8: 52-57.
- [4] 纪萍, 陈玲, 吴静妹. 基于能量差和支持向量机的电网扰动分类识别研究[J]. 石河子大学学报(自然科学版), 2020, 38(5): 548-553.
- JI P, CHEN L, WU J M. Research on power quality feature extraction method based on energy difference and SVM [J]. Journal of Shihezi University (Natural Science), 2020, 38(5): 548-553.
- [5] 赵庆生, 王雨滢, 梁定康, 等. 基于 BOF 图像检索算法的变电站设备图像分类[J]. 激光与光电子学进展, 2020, 57(18): 138-146.
- ZHAO Q S, WANG Y Y, LIANG D K, et al. Image classification of substation equipment based on BOF image retrieval algorithm [J]. Laser & Optoelectronics Progress, 2020, 57(18): 138-146.
- [6] 周封, 任贵新. 基于颜色空间变量的输电线图像分类及特征提取[J]. 电力系统保护与控制, 2018, 46(5): 89-98.
- ZHOU F, REN G X. Image classification and feature extraction of transmission line based on color space variable [J]. Power System Protection and Control, 2018, 46(5): 89-98.
- [7] 邹丹凤, 刘星, 蔡杰, 等. 基于改进卷积神经网络的电力设备红外图像分类识别方法[J]. 电力学报, 2023, 38(5): 412-419.
- ZOU D F, LIU X, CAI J, et al. Infrared image classification and recognition method of power equipment based on improved convolutional neural network [J]. Journal of Electric Power, 2023, 38(5): 412-419.
- [8] 刘宇, 侯北平, 张晓刚. 基于深度残差网络的电缆绝缘层截面图像分类研究[J]. 电线电缆, 2021(5): 17-23.
- LIU Y, HOU B P, ZHANG X G. Research on image classification of cable insulation layer cross section based on deep residual network [J]. Electric Wire Cable, 2021(5): 17-23.
- [9] 王雨滢, 赵庆生, 梁定康. 基于深度学习网络的电气设备图像分类[J]. 科学技术与工程, 2020, 20(23): 9491-9496.
- WANG Y Y, ZHAO Q S, LIANG D K. Electrical equipment image classification based on deep learning network [J]. Science Technology and Engineering, 2020, 20(23): 9491-9496.
- [10] TANG Z H, YAO J M, ZHANG Q. Multi-operator image retargeting in compressed domain by preserving aspect ratio of important contents [J]. Multimedia Tools and Applications, 2022, 1: 81.
- [11] 王满利, 陈冰冰, 张长森. 基于扩展大气散射模型的低光照图像增强算法[J]. 光子学报, 2023, 52(6): 218-235.
- WANG M L, CHEN B B, ZHANG C S. Low-light image enhancement via extend atmospheric scattering model [J]. Acta Photonica Sinica, 2023, 52(6): 218-235.
- [12] LIU Z M, YANG S B, WANG Y Z, et al. Multi-platform integration based on NIR and UV-Vis spectroscopies for the geographical traceability of the fruits of Amomum tsao-ko [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 258: 119872.
- [13] 赵小强, 张毓春. 基于双路并行多尺度 ResNet 的滚动轴承故障诊断方法[J]. 振动与冲击, 2023, 42(3): 199-208.
- ZHAO X Q, ZHANG Y C. Fault diagnosis method of rolling bearing based on dual-path parallel multi-scale ResNet method [J]. Journal of Vibration and Shock, 2023, 42(3): 199-208.
- [14] NIU C M, NAN F Z, WANG X R. A super resolution frontal face generation model based on 3DDFA and CBAM [J]. Displays, 2021, 69: 102043.
- [15] KUMAR P, HATI A S. Transfer learning-based deep CNN model for multiple faults detection in SCIM [J]. Neural Computing and Applications, 2021, 33: 15851-15862.
- [16] 薛健健, 马宏忠, 杨洪苏, 等. 基于格拉姆角场与迁移学习-AlexNet 的变压器绕组松动故障诊断方法[J]. 电力系统保护与控制, 2023, 51(24): 154-163.
- XUE J T, MA H Z, YANG H S, et al. A fault diagnosis method for transformer winding looseness

- based on Gramian angular field and transfer learning-AlexNet [J]. Power System Protection and Control, 2023, 51(24): 154-163.
- [17] WU H P, LI L. The BP neural network with Adam optimizer for predicting audit opinions of listed companies [J]. IAENG International Journal of Computer Science, 2021, 2: 364-368.
- [18] ALOTAIBI S D, YADAV K, ALEDAILY A N, et al. Deep neural network-based intrusion detection system through PCA [J]. Mathematical Problems in Engineering: Theory, Methods and Applications, 2022: 6488571.
- [19] 潘锦业, 王苗苗, 阚威, 等. 基于 Adam 优化算法和长短期记忆神经网络的锂离子电池荷电状态估计方法[J]. 电气技术, 2022, 23(4): 25-30.
- PAN J Y, WANG M M, KAN W, et al. State of charge estimation of lithium-ion battery based on Adam optimization algorithm and long short-term memory neural network [J]. Electrical Engineering, 2022, 23(4): 25-30.
- [20] 左一帆, 方玉明, 马柯德. 深度学习时代图像融合技术进展[J]. 中国图象图形学报, 2023, 28(1): 102-117.
- ZUO Y F, FANG Y M, MA K D. The critical review of the growth of deep learning-based image fusion techniques [J]. Journal of Image and Graphics, 2023, 28(1): 102-117.
- [21] 时维国, 吴宁. 基于小波包变换和 SVM 的三电平逆变器故障诊断[J]. 电机与控制应用, 2021, 48(2): 91-95.
- SHI W G, WU N. Fault diagnosis of three-level inverter based on wavelet packet transform and support vector machine [J]. Electric Machines & Control Application, 2021, 48(2): 91-95.
- [22] 王栋璀璨, 丁云飞, 朱晨烜, 等. 基于小波包和改进核最近邻算法的风机齿轮箱故障诊断方法[J]. 电机与控制应用, 2019, 46(1): 108-113.
- WANG D C, DING Y F, ZHU C X, et al. Fault diagnosis for wind turbine gearbox based on wavelet packet and improved kernel K-nearest neighbors algorithm [J]. Electric Machines & Control Application, 2019, 46(1): 108-113.
- [23] 柯皓, 关博凯, 王子豪, 等. 基于 MCS 和 AlexNet 的水润滑推力轴承故障检测[J]. 电机与控制应用, 2022, 49(11): 34-39.
- KE Z, GUAN B K, WANG Z H, et al. MCS and AlexNet based fault diagnosis of water-lubricated thrust bearing [J]. Electric Machines & Control Application, 2022, 49(11): 34-39.
- [24] 王浩楠, 蓝益鹏. 基于卷积神经网络的直线同步电动机电枢绕组故障诊断[J]. 电机与控制应用, 2021, 48(11): 72-79.
- WANG H N, LAN Y P. Fault diagnosis of armature winding of linear synchronous motor based on convolutional neural network [J]. Electric Machines & Control Application, 2021, 48(11): 72-79.
- [25] 李永萍, 杨艳春, 党建武, 等. 基于变换域 VGGNet19 的红外与可见光图像融合[J]. 红外技术, 2022, 44(12): 1293-1300.
- LI Y P, YANG Y C, DANG J W, et al. Infrared and visible image fusion based on transform domain VGGNet19 [J]. Infrared Technology, 2022, 44(12): 1293-1300.

收稿日期:2024-01-16

收到修改稿日期:2024-03-04

作者简介:

刘志坚(1975-),男,博士,教授,研究方向为电力系统优化控制、新能源并网稳定,248400248@qq.com;

*通信作者:刘航(1992-),男,博士,讲师,研究方向为高电压技术,电力设备状态评估与故障诊断,liuhangsheep@163.com。

Method for Substation Equipment Inspection Image Classification and Recognition Based on Improved ResNet34 Network

LIU Zhiyan, MENG Xinyu, LIU Hang*, LUO Linglin, ZHANG Dechun

(Faculty of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China)

Key words: ResNet34; convolutional block attention module; transfer learning; cosine annealing strategy

The safe and stable operation of power transmission and transformation equipment is crucial for ensuring the continuity of electricity supply, with the health monitoring of substation equipment being a key aspect of this goal. In recent years, substation equipment inspection image recognition technology has emerged as an effective monitoring tool, providing not only early warnings before faults occur but also helping to prevent potential equipment failures. However, this technology faces two main challenges in practical application: (1) limited accuracy in complex environment; (2) insufficient generalization capability. These shortcomings restrict the improvement of performance and accuracy of traditional classification recognition models.

Deep learning finely processes weights for diverse inputs received by neurons to achieve classification, endowing it with outstanding generalization capability and significant advantages in extracting key features. Although deep learning models are widely applied, there are two main challenges when dealing with large-scale and complex image data: (1) insufficient dataset samples; (2) difficulty in extracting features from complex backgrounds of inspection images, resulting in poor performance in image classification and

recognition.

Aiming at the above problems, an image classification and recognition method based on improved ResNet34 network is proposed. The seam carving algorithm is employed to compress the low-energy areas in the image for the preservation of key features. Additionally, six types of image enhancement techniques such as elastic transformation and Gaussian noise are utilized to increase the diversity of the images. The basic ResNet34 network is integrated with the convolutional block attention module to enhance the model's ability to extract key features from equipment inspection images. A model pre-trained on the ImageNet dataset is utilized as a feature extractor for transfer learning to address the issue of insufficient sample quantity. A cosine annealing strategy is introduced in the Adam optimizer to dynamically adjust the learning rate, to make the improved ResNet34 network converge to the optimal solution faster. Experimental results show that the proposed method improves accuracy by 0.073 3 and reduces the loss rate by 0.201 9 compared to the basic ResNet34 network, which provides a reliable solution for the field of substation equipment inspection image recognition.