

DOI:10.19651/j.cnki.emt.2209693

# 基于嵌入注意力机制的 UNet-DB\_ECA 网络检测金具研究\*

张 珊<sup>1</sup> 王文爽<sup>2</sup> 刘雪峰<sup>1</sup>

(1. 青岛科技大学自动化与电子工程学院 青岛 266061; 2. 山东省电力公司烟台供电公司互联网部 烟台 264000)

**摘 要:** 由于电力巡检中所拍摄的电力金具图片数量多,检查工作量大,为了提高电力金具的自动化检测效果,本文基于 UNet 框架提出了一种 UNet-DB\_ECA 网络检测金具的方法。先降低 UNet 网络宽度,然后在网络中嵌入高效通道注意力机制模块 ECANet (ECANet) 和批量规范化 (BN),最后引入了 Hard-Swish 激活函数,从而构建了 UNet-DB\_ECA 网络。本文使用电力金具检测数据集进行实验,实验结果表明本文所提出的方法检测效果良好,与 UNet 网络检测效果相比,在提升检测效果的同时也兼顾了算法性能。此外,电力金具检测数据集中包含七类形状不同的金具类型,另一方面也表明本文所提方法具有较好泛化能力,因此该方法在电力金具自动化检测方面具有一定的应用前景。

**关键词:** 深度学习; UNet 网络; 注意力机制; 电力金具; 智能巡检

**中图分类号:** TP18 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## Research on UNet-DB\_ECA network detection of electric power fittings based on embedding attention mechanism

Zhang Shan<sup>1</sup> Wang Wenshuang<sup>2</sup> Liu Xuefeng<sup>1</sup>

(1. College of Automation & Electric Engineering, Qingdao University of Science & Technology, Qingdao 266061, China;

2. Yantai Power Supply Company of State Grid Shandong Electric Power Company, Yantai 264000, China)

**Abstract:** Due to the large number of pictures of electric power fittings taken in the power inspection, the inspection workload is large. In order to improve the automatic detection effect of electric power fittings, this paper proposes a UNet-DB\_ECA (UNet Dimensionality Reduction, BN, and ECANet, UNet-DB\_ECA) network detection method based on UNet network. First reduce the width of the UNet network, then embed the efficient channel attention mechanism module ECANet (Efficient Channel Attention Networks, ECANet) and Batch Normalization (BN) in the network, and finally introduce the Hard-Swish activation function, thus constructing UNet-DB\_ECA network. This paper uses the electric power fittings detection dataset to conduct experiments. The experimental results show that the method proposed in this paper has a good detection effect. Compared with the UNet network detection effect, it improves the detection effect and also takes into account the algorithm performance. In addition, the power fittings detection dataset contains seven types of fittings with different shapes, which shows that the method proposed in this paper has good generalization ability, so the method has certain application prospects in the automatic detection of power fittings.

**Keywords:** deep learning; UNet network; attention mechanism; electric power fittings; intelligent inspection

## 0 引 言

随着中国输电线路的高速发展,电网逐步实现了全面覆盖,而电力金具作为输电线路分布广泛的金属附件,其长期暴露于复杂的野外环境<sup>[1]</sup>,极易发生磨损、锈蚀、开裂

以及螺栓松动等故障,加之电网运行年限渐长,国家电网输电线路因金具损坏所引发的故障发生概率呈上升趋势<sup>[2]</sup>,输电线路的运维成本逐渐加重,因此迫切地需要一项检测技术以实现自动化、智能化地检测电力金具,从而减轻基层巡检作业负担<sup>[3]</sup>。

收稿日期:2022-04-21

\* 基金项目:国家自然科学基金(61971253)、山东省自然科学基金(ZR201910300033)项目资助

在早期,电力金具的检测算法以人工设计特征的传统图像处理方法为主<sup>[4]</sup>。Wu 等<sup>[5]</sup>利用灰度与平均梯度搭建检测模型,通过间隔棒的轮廓特征实现检测。张桂南和刘志刚<sup>[6]</sup>通过人工设计的 Harris 角点特征对绝缘子进行角点检测,然后对这些匹配角点进行谱聚类等传统图像处理操作,最终实现绝缘子故障检测。宋伟等<sup>[7]</sup>通过采用直方图均衡化、形态学处理和 RGB 彩色模型三种图像处理技术相结合的方法实现检测防震锤锈蚀缺陷。张兴森等<sup>[8]</sup>运用主分量分析法提取缺陷信息特征后采用支持向量机法自动识别缺陷。姜哲<sup>[9]</sup>通过计算机视觉与图像处理技术相结合的方法实现电力设备的智能故障检测。但这些早期传统的电力金具检测算法存在普遍的缺陷,其对特征的处理较单一<sup>[10]</sup>,容易受到图像背景、光线、角度等信息干扰,缺乏泛化能力<sup>[11]</sup>,并且存在计算复杂度高以及鲁棒性差的缺陷<sup>[12]</sup>,无法实现在现实场景中广泛应用。

近年来,随着计算机硬件技术以及大数据的飞速发展,深度学习逐渐成为人工智能检测领域的研究热点和主流发展方向<sup>[13]</sup>。Mao 等基于 SGCS(sum of absolute differences + graph cuts)的立体匹配算法,采用灰度分布双峰法对无人机双目摄像机得到的视差图进行分割和比较,从而找到图像分割的最佳阈值,然后通过方向梯度直方图提取特征,再利用有向无环图支持向量机训练缺陷识别模型<sup>[14]</sup>,但这种基于机器学习的检测方法对于背景复杂的电力金具图像检测效果则并不理想。Wan 等<sup>[15]</sup>在基于区域的全卷积网络基础上提出了一种结合输电线路金具之间细粒度特征和上下文信息的目标检测方法,将可变形卷积层和 SENet(squeeze and excitation networks)模块加入到检测模型中,从而进一步提高输电线路航拍图像的检测效果。赵振兵等<sup>[16]</sup>提出了一种结合深度网络和逻辑回归模型的因果分类方法,使用 VGG16 模型提取深度特征,通过缺陷特征与标签之间的因果关系学习来构建因果逻辑回归模型。武学良<sup>[17]</sup>通过在 Faster R-CNN 网络中嵌入双注意力机制,从而实现对不同尺度和不同位置的视觉特征进行分析增强,进而达到对航拍输电线路螺栓缺陷的检测效果。江爱雪<sup>[18]</sup>在 SSD 模型中嵌入金具之间的遮挡关系模块,从而提高模型检测精度。深度学习可以通过使用多层卷积神经网络提取图像更高层、更抽象的特征,从而实现自动提取特征<sup>[19]</sup>,这大大减少了人工设计特征的传统方法所带来的复杂度。但对于电力金具的检测,目前大多数研究人员所采用的神经网络层数较多,网络结构较为复杂,中间特征需要磁盘存储,模型训练时间长,如 RCNN<sup>[20]</sup>、SPPNet<sup>[21]</sup>、Faster R-CNN<sup>[22]</sup> 等算法,但若减少检测耗费时间,从双阶段整合为单阶段检测则会又导致一定程度上降低检测精度<sup>[23]</sup>,如 YOLO<sup>[24]</sup>、SSD<sup>[25]</sup> 等算法。

而在医学领域自动化检测病灶研究中广泛使用的 UNet 网络具有检测精度高,网络结构简单的优点。因此,本文将基于分割领域中常用的 UNet 网络<sup>[26]</sup>进行改进,并

在网络中嵌入高效通道注意力机制(efficient channel attention net, ECANet)模块,引入批量规范化(batch normalization, BN)操作,此外不再单一的仅选择 ReLU(rectified linear unit, ReLU)激活函数,在网络中加入了 Hard-Swish 激活函数,从而构建了新网络 UNet-DB\_ECA(UNet dimensionality reduction, BN, and ECANet, UNet-DB\_ECA)模型,实验验证本文方法能有效提高对电力金具检测的精度且具有一定的泛化性,对多类不同形状的电力金具类别均能实现较好检测效果,为促进深度学习与电力巡检的有机融合,实现自动化、智能化检测电力金具提供了新思路。

## 1 相关简介

### 1.1 UNet 网络

UNet 网络<sup>[27]</sup>是 Ronneberger 等在 2015 年提出的一个基于卷积神经网络(convolution neural network, CNN)的图像分割网络,该网络结构在小数据集上也可以获得较好的分割效果。UNet 网络通过卷积操作进行图像特征提取,基于 CNN 采用编码器与解码器的思路,搭建了完全对称的 U 型结构网络,其中 U 型结构的左半边为收缩路径,用以获取上下文的特征信息,而 U 型结构的右半边为扩张路径用以获取位置信息。整个网络进行了 19 次卷积操作,使用整流线性单元(rectified linear unit, ReLU),4 次池化操作,4 次上采样操作,以及 4 次长连接,而网络中长连接的引入实现了网络低维度与高维度的信息融合。通过 UNet 网络可以实现像素级分类,其分割的准确率不仅较之以往的全卷积网络有极大的提升,而且在较小的数据集上的训练结果也很优异,因而 UNet 网络的提出极大的推进了图像分割检测领域的研究。具体的 UNet 网络结构如图 1 所示。

### 1.2 高效通道注意力机制模块

注意力机制是让机器模仿人类感知的注意力行为,从而实现自行区分数据中的重要部分与不重要部分,从而实现在众多信息中对关键信息保持较高关注度。注意力机制通过对模型的每一个输入项分配不同大小的权重来决定对哪些信息进行侧重,这可以有效提高模型的性能。压缩和激励网络模块(squeeze-and-excitation networks, SENet)<sup>[28]</sup>是对通道注意力机制的典型实现,但它对所有通道进行捕获的行为会降低模型效率,而卷积则具有良好的跨通道信息获取能力,因此 Wang 等<sup>[29]</sup>提出了高效通道注意力机制网络 ECANet(efficient channel attention networks, ECANet),将原来 SE 模块中的全连接层替换为卷积核大小为 5 的 1 维卷积。ECANet 网络结构如图 2 所示。

### 1.3 批量规范化

对于一个多通道的输入特征层,标准化处理就是对该特征层的每一个通道都进行标准化处理,这样可以加速网络收敛。理论上应该对整个训练集所对应的特征层数据进




图 1 UNet 网络结构




图 2 ECA-Net 网络结构

行标准化处理,从而让其满足相同的分布规律,但是这对于大型的数据集是难以实现的,因此谷歌团队在 2015 年提出了批量规范化(batch normalization, BN)<sup>[30]</sup>,先一个个的计算批次数据的特征图然后再对批次进行标准化,该方法不仅加速了网络的收敛速度,而且对准确率也有较大提升。

## 2 UNet-DB\_ECA 网络结构设计

### 2.1 改进 UNet 网络大小

Ronneberger 等提出 UNet 网络的时间是 2015 年,但当时受到显存性能的限制,网络输出的分割特征图并不是原图  $572 \times 572$  的大小,而是原图中心的  $388 \times 388$  大小区域,而对于  $388 \times 388$  以外的边缘所缺失的信息则采用镜像进行补充。此外,原始 UNet 网络并没有进行填充(padding)操作,这就导致每次卷积操作之后,图像长与宽的长度都会减缩 1,而在进行之后的跳跃连接(skip connection)时,需要先进行中心裁剪,将收缩路径中每层下采样之前的特征图像裁剪至与对应扩张路径中每层上采样之后的特征图尺寸相同后再进行拼接操作。

随着计算机硬件的飞速发展,目前大部分显存性能都能满足基本的深度学习需求,因此本文在 UNet 网络的每次卷积操作中都加入 padding 操作,从而保证输入图片在卷积之后大小不变,使收缩路径与对应的扩张路径的每一层上的特征图像大小可以保持一致,进而在 skip connection 操作时不需要再进行中心裁剪,可以直接进行

拼接,简化了网络模型的操作,此外,这也使得网络输出的最终分割特征图与原图大小保持一致,这有效的提高了网络输出的分割特征图的精度。

此外,由于 UNet 网络的卷积层的激活函数使用的是 ReLU 函数,而对于这样的勒贝格可积函数,其不能被一个宽度小于  $n$  的 ReLU 网络逼近<sup>[31]</sup>,而减少这些函数的宽度,用于补偿模型性能的深度不是呈指数级增长,而是多项式增长,这反应出网络的宽度并没有深度重要。在另一方面,UNet 作为卷积神经网络的一种类型,其在网络深度上的相关计算量为  $O(n)$ ,而在网络宽度上则为  $O(n^2)$ ,因而更窄的网络宽度可以使模型训练时拥有更少的参数。因此本文通过降低 UNet 网络中的网络宽度进行改进,在网络的收缩路径中第四层下采样里,并没有像原始 UNet 网络一样增加一倍网络宽度,而是让其仍然保持原有 512 个通道数目,在之后的网络扩张路径中,每一层上采样之后的长连接仍然保留,但前三次上采样之后的两次卷积操作相较于原始 UNet 网络的卷积操作,其卷积核个数减少了一半。

### 2.2 UNet 网络嵌入注意力机制与 BN

由于前面对原始 UNet 网络进行了减少通道数的改进,改进后的窄宽度网络虽然一方面大大减少模型参数,降低了模型的计算量,但另一方面也意味着需要充分利用网络所保留的通道,为了提高每一层的通道利用率,本文在原始 UNet 网络中的每一层上采样之前都嵌入了 ECA-Net 模块,一共嵌入了 4 次注意力机制模块,从而尽可能的提高网络通道的利用率,避免由于网络宽度的降低所导致的网络通道信息损失。此外,为了加速网络的收敛速度以及进一步提升网络的准确率,本文在原始 UNet 网络的每个卷积层之后,激活层之前加入了 BN 操作,神经网络训练的过程中是将整个数据集分割为一个个批次(batch)的数据进行训练的,BN 操作就是对这一个个 batch 数据进

行标准化操作,从而使训练集的特征图满足均值为 0,方差为 1 的分布规律,进而达到加速网络收敛的效果。由于在 UNet 网络中引入 BN 操作,卷积层的偏置则不会再起到任何作用,因此本文将卷积层的偏置统一设置为 0。

### 2.3 激活函数的选择

在深度学习中,选择合适的激活函数有助于网络的训练以及提高任务精度。在原始 UNet 网络的隐藏层均使用的是 ReLU 激活函数,ReLU 函数的定义如式(1)所示。

$$ReLU(x) = \max(0, x) \tag{1}$$

由式(1)可以看出,ReLU 激活函数在  $x > 0$  区域上,不会出现梯度爆炸或梯度弥散问题,但在  $x < 0$  区域上,梯度为 0,因此如果在训练过程中突然产生一个巨大的梯度使下一次输入数据的分布中心在  $x < 0$  区域上,就会出现大面积的神经元坏死现象(dead ReLU problem),这就导致采用 ReLU 激活函数的网络在一定程度上不容易训练。2017 年<sup>[32]</sup> Ramachandran 等利用自动搜索技术发现使用 Swish 函数可以获得比 ReLU 函数更好的结果。Swish 函数的公式如式(2)所示。

$$Swish(x) = x \cdot sigmoid(\beta x) = x \cdot \frac{1}{1 + e^{-\beta x}} \tag{2}$$

其中,  $\beta$  为常数或可训练参数,Swish 函数同 ReLU 函数一样是上界无限,下界有限的,但二者的显著区别是  $x < 0$  时,Swish 具有非单调性。Swish 是平滑且非单调的函数。

尽管选择 Swish 激活函数的网络能有效提高提高任务精度,但另一方面 Swish 激活函数运算包含有 sigmoid 激活函数,它是一个指数函数,这在一定程度上增加了计算量,而 Howard 等人在 2019 年提出的 Hard-Swish 激活函数<sup>[33]</sup>则较好的考虑到了这个问题,Hard-Swish 激活函数的公式如式(3)所示。

$$Hard-Swish(x) = \begin{cases} 0, & x \leq -3 \\ x, & x \geq +3 \\ x \cdot \frac{x+3}{6}, & \text{其他} \end{cases} \tag{3}$$

由于 Swish 类激活函数只有在更深的网络层中使用才具有优势,因此在 UNet 网络中对激活函数的选择本文参考了 MobileNetV3 网络对激活函数的选择,仅仅在 UNet 网络的下采样前的前两层卷积操作以及每次上采样之后的卷积操作后使用 Hard-Swish 激活函数,其余部分与原 UNet 网络的激活函数一致,依然使用 ReLU 激活函数。以上所提到的各类激活函数图像如图 3 所示。




图 3 激活函数图像

### 2.4 UNet-DB\_ECA 网络原理及系统架构

本文所提出的 UNet-DB\_ECA 网络是在 UNet 网络的基础上进行改进,首先通过减少卷积操作中的卷积核个数从而降低原始 UNet 网络宽度,其次在原始 UNet 网络的每次上采样之前嵌入高效通道注意力机制模块 ECANet,此外在卷积层之后加入 BN 操作,从而进一步提高网络模型的性能,加速网络收敛,最后改变了原始 UNet 网络对激活函数的选择,在收缩路径中每次下采样后的卷积层后的激活层依然选择 ReLU 激活函数,但除此之外的激活层中的激活函数从 ReLU 改变为 Hard-Swish,Hard-Swish 激活函数的为网络带来了更优的性能,UNet-DB\_ECA 网络的总体网络框架如图 4 所示。

将本文所提的 UNet-DB\_ECA 网络应用到电力金具数据集中,其整体的检测系统流程如图 5 所示。首先将电力金具数据集随机打乱后划分成训练集和测试集,然后进




图 4 UNet-DB\_ECA 网络的总体网络框架

行图片预处理后使用本文方法 UNet-DB\_ECA 网络进行模型训练,当训练的 Epoch 达到 100 时结束训练,此时得到训练好的网络模型,将其放到图片预处理后的电力金具测试集上进行测试,得到模型对金具的检测图,模型检测图可更加突出的显示出电力金具的位置,将有助于地面工作人员在检测图片时更加高效的检测电力金具状态是否正常,进而有效提高检查工作效率。此外可进一步计算检测效果评价指标,以便进一步评测模型的性能。

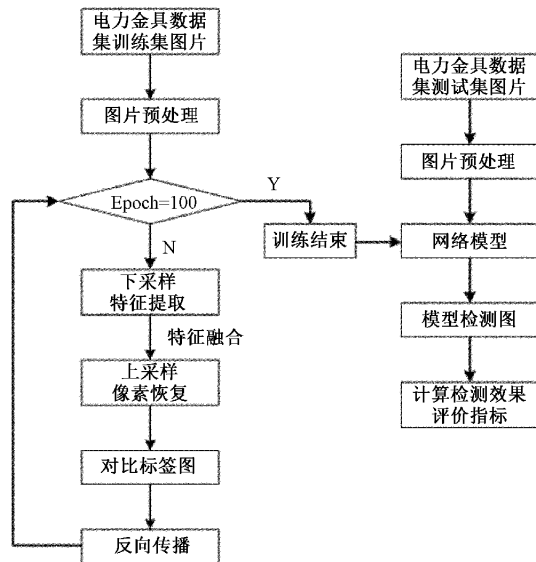


图 5 电力金具检测系统流程

### 3 实验过程与结果分析

#### 3.1 数据集及其预处理

本文所使用的电力金具检测数据集是由电力巡检过程中所拍摄的图像组成,一共包括悬垂线夹、球头挂环、平行挂板、U 形挂环、防振锤、延长环、心形环 7 类电力金具,一共 5 336 张图像,参考 PASCAL VOC 数据集的构建方法,使用 Labelimg 软件严格按照标注规范对电力金具目标进行标注,从而构建了专业的电力金具检测数据集,其中有 3 476 张悬垂线夹图像,2 251 张球头挂环图像,693 张平行挂板图像,4 795 张 U 型挂环图像,941 张防振锤图像,782 张延长环图像,2 251 张心形环图像,该 7 类电力金具图像的所有图像进行打乱随机划分,其中训练集与测试集的数量比例为 7 : 3,打乱的随机种子 seed 为 1 337,数据集各类电力金具数量表如表 1 所示。

电力金具检测数据集中的图像像素尺寸集中在 2 000 ~ 5 000 像素值,但受制于实验室的图形工作站的 GPU 显卡性能,将完整的原始图片作为数据集送入神经网络模型中进行训练会发生内存溢出的情况,因此本文在将图片送入网络模型中训练之前集中进行了预处理,在不损失原始图像信息的前提下,先将图像尺寸大小统一调整为 512 × 512 像素值,然后再进行灰度化处理,这不仅大大降低了网络

表 1 数据集各类电力金具数量表

	训练集	测试集
悬垂线夹	2 433	1 043
球头挂环	1 576	675
平行挂板	485	208
U 型挂环	3 356	1 439
防振锤	658	283
延长环	547	235
心型环	1 192	511

模型训练过程中对硬件显存的要求,而且也极大的提高了模型的训练速度。

#### 3.2 实验设备与网络训练

本文实验均使用一张 NVIDIA GeForce GTX1080Ti 的 GPU 显卡进行模型的训练与测试,利用 CUDA10.1 加速训练,在 Ubuntu 16.04.7 LTS 操作系统下,使用 Python3.7 编程语言,以 PyCharm2020 和 Anaconda 搭建开发环境,PyTorch1.7.0 深度学习框架搭建实验程序运行环境。

本文中的所有实验全部使用 RMSprop 优化算法,根据实验室图形工作站所配置的计算机硬件性能,网络训练时的 batch\_size 设置为 4,epochs 设置为 100。网络训练参数表如表 2 所示。

表 2 网络训练参数表

	参数	值
RMSprop 优化算法	learn rate	0.000 01
	momentum	0.9
	weight_decay	$1 \times 10^{-8}$
网络训练	batch_size	4
参数细节	Epochs	100

#### 3.3 检测精度评估指标

本文实验中电力金具检测的精度评判标准选用准确率(accuracy, Acc)、平均交并比(mean intersection-over-union, mIoU)、召回率(recall, R)、精准度(precision, PR)以及 F1 分数(F1-Score, F1)5 个指标。这 5 个精度评估指标均是基于混淆矩阵进行计算,混淆矩阵如表 3 所示。

表 3 混淆矩阵表

实际结果	检测结果	
	真实目标	非真实目标
真实目标	TP	FN
非真实目标	FP	TN

交并比(intersection-over-union, IoU)是对某一类目标检测的真实结果与真实值的交集与并集的比值。其计算公式如式(4)所示。

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

平均交并比是对每一类的交并比求和后取平均值的  
结果。其计算公式如式(5)所示。

$$mIoU = \frac{\sum_i IoU}{n} \quad (5)$$

召回率是指在样本中的实际目标结果中,检测结果正  
确所占的比例。其计算公式如式(6)所示。

$$R = \frac{TP}{TP + FN} \quad (6)$$

精准率在目标类别的预测值中,计算真实的属于该类  
别的像素准确率。其计算公式如式(7)所示。

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

召回率与精准率两个指标存在一定的矛盾,而 F1 分  
数则可以同时考虑到这两个指标<sup>[34]</sup>,它是二者的调和平均  
数,可以使其达到平衡状态下最高值。其计算公式如  
式(8)所示。

$$F1 = 2 \times \frac{PR \times R}{PR + R} \quad (8)$$

准确率是指检测类别正确的像素数占总像素数的比  
例。其计算公式如式(9)所示。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

### 3.4 UNet-DB\_ECA 网络检测结果与分析

为了展示本文所提的 UNet-DB\_ECA 网络的性能,对

UNet-DB\_ECA 网络进行了实验验证,其与 UNet 网络的  
算法性能结果对比表以及检测精度结果对比表分别如  
表 4、5 所示。从算法性能上看,UNet-DB\_ECA 网络相较  
于 UNet 网络,网络训练耗时最低提升了 11.78%,这表明  
改进原始 UNet 网络的网络宽度有效的降低了模型的相关  
计算量,提高了模型训练速度,此外,尽管 UNet-DB\_ECA  
网络是在 UNet 网络中嵌入注意力机制模块、BN 操作,以  
及引入了 Hard-Swish 激活函数进行改进的,但这些改变  
并没有给网络带来太多计算量,反而降低网络宽度减少了  
大量的相关计算量,从总体上看,UNet-DB\_ECA 网络相比  
于 UNet 网络是轻量化的,因此本文算法的性能相比于  
UNet 网络是有所提升的。而从检测精度上看,UNet-DB\_  
ECA 网络表现出了较大的精度提升,在电力金具检测数据  
集中,但就 mIoU 指标,悬垂线夹、球头挂环、平行挂板、U  
型挂环、防振锤、延长环以及心型环分别提升了 3.11%、  
3.39%、13.50%、4.99%、5.79%、9.16% 以及 8.38%,可  
以看出对于数据集样本越少的类别如平行挂板、延长环等  
金具类别,本文算法对精确度的提升越大,这充分说明了  
本文算法对提高巡检任务的检测精度是非常有利的,对小  
数据集检测效果尤其友好。从表 5 整体上看,UNet-DB\_  
ECA 网络在 Acc、mIoU、R 以及 F1 四项评价指标上均得  
到提升,这充分说明本文算法有助于电力金具实现高效  
化、自动化、智能化的检测,为电力金具与深度学习的有机  
结合提供了一种新思路。

表 4 算法性能结果对比表

电力金具检测类别	训练集平均耗时			验证集平均耗时		
	UNet/(it/s)	本文算法/(it/s)	提升率/%	UNet/(it/s)	本文算法/(it/s)	提升率/%
悬垂线夹	2.87	3.34	16.37	19.30	21.21	9.90
球头挂环	2.96	3.46	16.89	18.83	21.69	15.19
平行挂板	2.87	3.38	17.78	18.56	19.19	3.39
U 型挂环	2.97	3.32	11.78	19.48	21.56	10.67
防振锤	2.96	3.31	11.82	18.34	21.49	17.17
延长环	2.95	3.38	14.58	19.80	22.33	12.78
心型环	3.00	3.41	13.67	19.36	21.41	10.59

表 5 检测精度结果对比表

电力金具 检测类别	UNet					UNet-DB_ECA				
	Acc	mIoU	R	PR	F1	Acc	mIoU	R	PR	F1
悬垂线夹	97.73	86.72	80.16	93.42	86.28	98.18	89.42	86.26	92.76	89.39
球头挂环	99.09	85.55	81.06	86.62	83.75	99.31	88.45	82.86	92.44	87.39
平行挂板	98.03	61.33	27.36	71.19	39.53	98.49	69.61	44.23	83.82	57.90
U 型挂环	98.11	78.27	64.74	85.79	73.79	98.46	82.18	72.95	87.30	79.48
防振锤	99.41	75.14	53.09	92.38	64.43	99.51	79.49	63.38	90.60	74.58
延长环	97.70	61.89	29.55	69.01	41.38	97.93	67.56	44.55	69.34	54.25
心型环	98.04	70.37	46.98	82.53	59.88	98.39	76.27	61.13	82.65	70.28

### 3.5 不同网络的对比分析

为了更好的展现各个网络在电力金具检测数据集上的检测效果,在定量分析上,本文进行了消融实验,实验结果以 mIoU 做为电力金具类别检测精度对比,前 4 列分别为电力金具的 mIoU 检测精度结果,最后 1 列为各个网络的训练总参数量。消融实验结果如表 6 所示。从表 6 中可以看出,对于数据集样本图像越少的电力金具类别,本文所提的 UNet-DB\_ECA 网络提升效果越大,而对于数据集样本图像

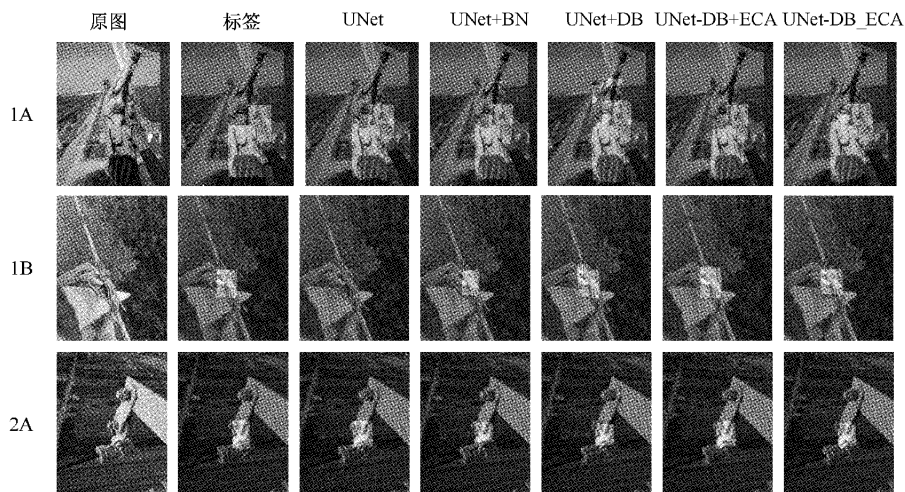
较多的电力金具类别,加入 Hard-Swish 激活函数的 UNet-DB\_ECA 网络对比未加 Hard-Swish 激活函数的 UNet-DB+ECA 网络在检测精度上略微有所下降,这可能是由于足够的样本图片已经使模型具有较好的拟合效果,进一步加入 Hard-Swish 激活函数反而导致了模型出现过拟合现象,但从整体上看,UNet-DB\_ECA 网络对电力金具检测数据集的七类不同金具的检测效果是最好的,因此本文所提算法对各类电力金具检测具有较好的检测效果。

表 6 消融实验对比

	悬垂线夹	球头挂环	平行挂板	U 型挂环	防振锤	延长环	心型环	网络参数量
UNet	86.72	85.55	61.33	78.27	75.14	61.89	70.37	31 030 593
UNet+BN	87.64	87.67	63.85	80.15	76.04	63.39	72.45	31 036 481
UNet-DB	88.05	87.90	65.90	80.82	76.86	64.18	73.51	13 394 177
UNet-DB+ECA	89.69	88.45	67.53	82.82	77.78	67.27	76.03	13 394 195
UNet-DB_ECA	89.42	88.45	69.61	82.18	79.49	67.56	76.27	13 394 195

另一方面,在定性分析上,各网络目标检测效果如图 6 所示,从 1 行至第 8 行,同一类电力金具类别分别展示 A、B 两张图像,一共展示出类别 1 悬垂线夹、类别 2 球头挂环、类别 3 平行挂板、类别 4 U 型挂环、类别 5 防振锤、类别 6 延长环以及类别 7 心型环七种电力金具类别图片,因此这 7 类图的命名分别为类别数加图像名。各网络检测目标效果图中的第 1 列为数据集中的原图,命名为图号(a);第 2 列为严格按照 PASCAL VOC 数据集的构建方法进行标注的标签,命名为图号(b);第 3 列为 UNet 网络检测效果,命名为图号(c);第 4 列为 UNet+BN 网络检测效果,即 UNet 网络中引入了 BN 操作,命名为图号(d);第 5 列为 UNet-DB 网络检测效果,即在 UNet 网络引入 BN 操作的基础上减少网络卷积核个数,降低网络中部分特征层的维度的网络,命名为图号(e);第 6 列为 UNet-DB+ECA 网络检测效果,即在 UNet-DB 网络的基础上,在每一层上采样中嵌入了注意力机制模块 ECA,命名为图号(f);第 7 列为本文算法 UNet-DB\_

ECA 网络的检测效果,命名为图号(g)。因此图六中的每张图片命名为类别名加图像名加图号名。从图 6 中的各网络目标检测效果图中,可以看到在 UNet、UNet+BN、UNet-DB、UNet-DB+ECA 以及 UNet-DB\_ECA 五个网络中,UNet-DB\_ECA 网络的检测效果最好,其检测边缘更光滑,过渡更平滑,更加贴合于电力金具检测数据集中标注的标签。并且对于电力金具中相互遮挡情况复杂的图像如 1A 系列图中,UNet-DB\_ECA 网络依然可以很好的检测到目标,这展现出 UNet-DB\_ECA 网络在实际应用上的较大的优势,将该网络训练所得的模型应用到电力金具检测系统中进行检测,从而实现自动化检测电力金具目标。从图 6 中可以看出该网络获得的检测效果最优,这将更容易使工作人员关注到待检测的电力金具图像中的金具目标,从而有效提高检查金具故障的效率,减轻电力巡检过程中地面站的工作人员的检测工作量。实验结果表明本文所提方法在电力金具自动化检测方面具有良好的应用前景。



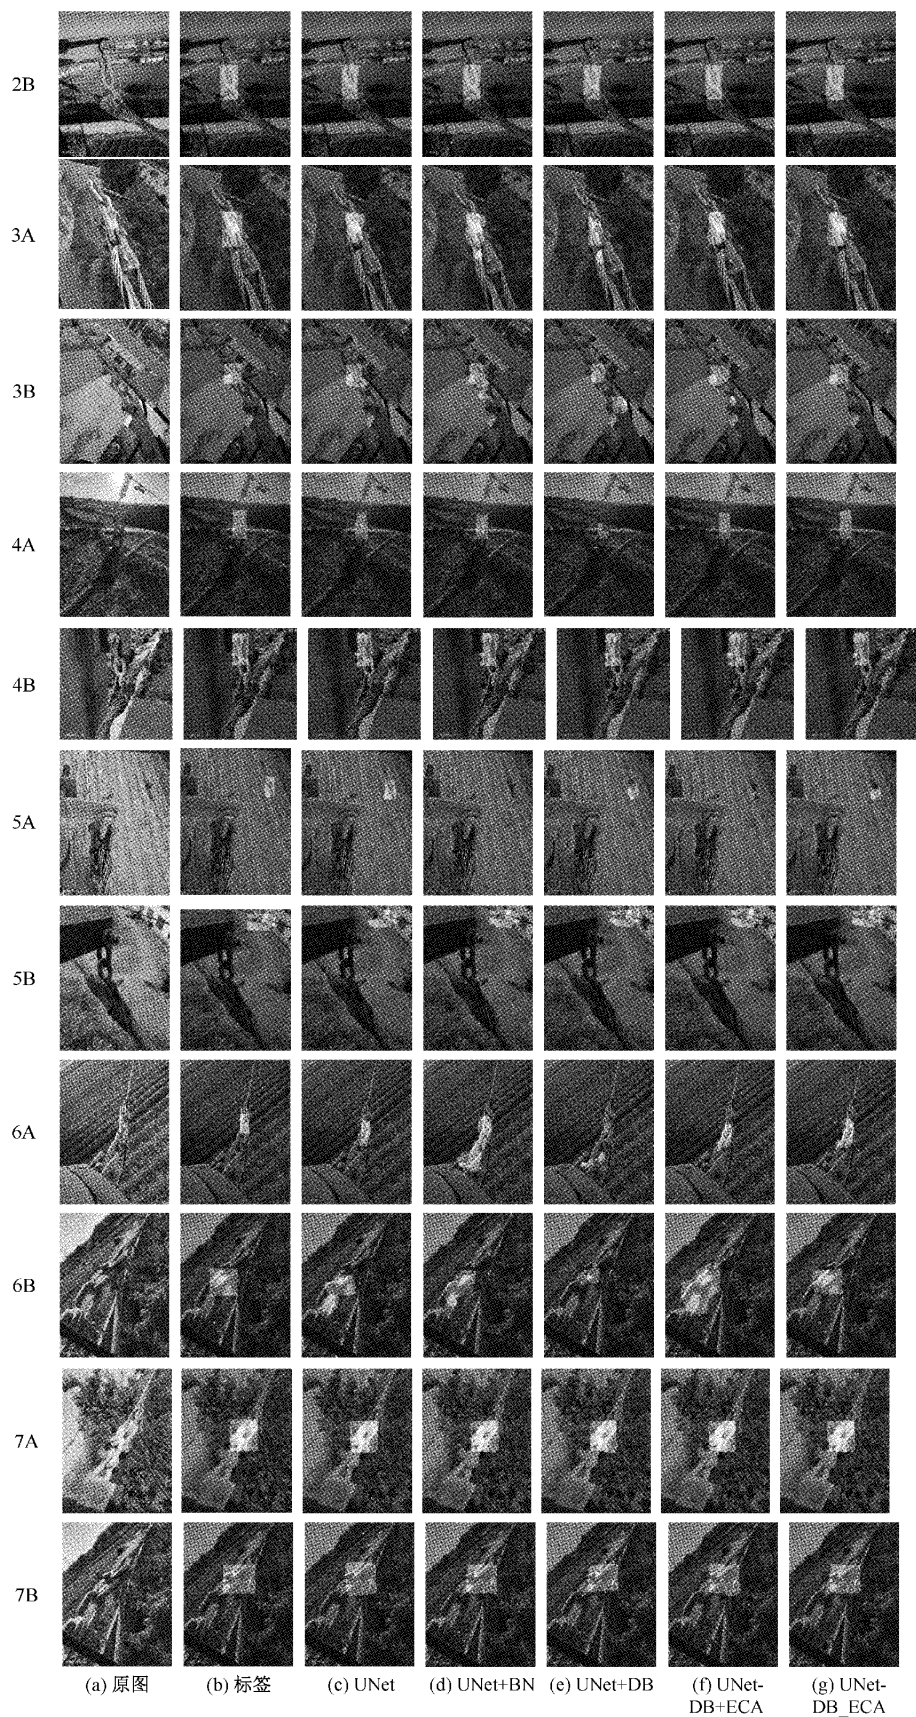


图 6 各网络目标检测效果图



## 4 结 论

本文提出的嵌入注意力机制的 UNet-DB\_ECA 网络检测方法,可以实现对电力金具目标的自动化检测,从而减轻电路巡检后对海量拍摄图像的检查工作量,更好的帮助巡检人员发现高压输电线上电力金具的异常点,进而高效保障输电线路的可靠安全。

本文在 UNet 原始网络的基础上,通过降低部分卷积操作中卷积核个数进行改进,从而减少网络中间特征图的维度,降低网络宽度,改进后的窄宽度网络经实验验证,其不仅大大地降低了神经网络的相关计算量,使模型训练时长缩减,在算法性能上表现出较大的优越性,而且对电力金具的检测精度也有所提升,这表明原始 UNet 网络中 U 型底层的 1 024 维度的特征层可能是存在冗余信息的,缩减为 512 是一种有效的改进方式。另一方面,虽然缩减了网络宽度,但在另一方面本文也在 UNet-DB 网络的每一层上采样之前均加入了高效通道注意力机制模块 ECANet,且在整个网络的每一层卷积层之后加入了 BN 操作,实验结果也验证该操作对电力金具检测精度有进一步提升。最后,为了进一步提高检测精度,本文在较深的上采样卷积层中也引入了 Hard-Swish 激活层,改进后的检测算法展现出优良性能,这为智能自动化检测电力金具巡检图像提供了新思路。

此外,虽然本文所提的算法在精度和性能上均有所提升,但数据集中存在个别电力金具类别的样本图像较少的问题,未来将考虑对电力金具数据进行虚拟样本扩充以便进一步提高检测精度。

## 参考文献

- [1] 张薇. 基于关系推理的输电线路金具及其缺陷检测方法[D/OL]. 保定:华北电力大学, 2021.
- [2] 耿慧敏. 输电线路金具常见故障及结构改进分析[J]. 硅谷, 2013, 6(18): 135,126.
- [3] 赵振兵, 蒋志钢, 李延旭, 等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报, 2021, 26(11): 2545-2560.
- [4] 陶筱娇, 王鑫. 基于深度学习算法的图像分类方法[J]. 微型电脑应用, 2019, 35(3): 40-43.
- [5] HAIBIN W, YANPING X, WEIMIN F, et al. Damper detection in helicopter inspection of power transmission line [C]. 2014 Fourth International Conference on Instrumentation and Measurement, Computer, Communication and Control, IEEE, 2014: 628-632.
- [6] 张桂南, 刘志刚. 基于角点匹配与谱聚类的接触网绝缘子破损/夹杂异物故障检测[J]. 仪器仪表学报, 2014, 35(6): 1370-1377.
- [7] 宋伟, 左丹, 邓邦飞, 等. 高压输电线防震锤锈蚀缺陷检测[J]. 仪器仪表学报, 2016(37): 113-117.
- [8] 张兴森, 边美华, 梁庆国, 等. 基于涡流检测的电力线夹缺陷检测与分类方法[J]. 中国科技论文, 2017, 12(4): 454-458.
- [9] 姜哲. 无人机巡线电力设备故障的视觉检测技术[D/OL]. 成都:电子科技大学, 2017.
- [10] 吕璐, 程虎, 朱鸿泰, 等. 基于深度学习的目标检测研究与应用综述[J]. 电子与封装, 2022, 22(1): 72-80.
- [11] 赵振兵, 熊静, 李冰, 等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术, 2021: 1-9.
- [12] ZOU Z, SHI Z, GUO Y, et al. Object detection in 20 years: A survey [J]. ArXiv Preprint, 2019, ArXiv:1905.05055.
- [13] 吴雪, 宋晓茹, 高嵩, 等. 基于深度学习的目标检测算法综述[J]. 传感器与微系统, 2021, 40(2): 4-7,18.
- [14] MAO T, HUANG K, ZENG X, et al. Development of power transmission line defects diagnosis system for UAV inspection based on binocular depth imaging technology[C]. 2019 2nd International Conference on Electrical Materials and Power Equipment(ICEMPE), IEEE, 2019: 478-481.
- [15] WAN N, TANG X, LIU S, et al. Transmission line image object detection method considering fine-grained contexts[C]. 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference(ITNEC), IEEE, 2020, 1: 499-502.
- [16] 赵振兵, 张薇, 戚银城, 等. 融合深度特征的输电线路金具缺陷因果分类方法[J]. 北京航空航天大学学报, 2021, 47(3): 461-468.
- [17] 武学良. 嵌入双注意力机制的 Faster R-CNN 航拍输电线路螺栓缺陷检测[D/OL]. 保定:华北电力大学, 2021.
- [18] 江爱雪. 基于 SSD 的输电线路典型金具图像检测方法研究[D/OL]. 保定:华北电力大学, 2020.
- [19] 南晓虎, 丁雷. 深度学习的典型目标检测算法综述[J]. 计算机应用研究, 2020(37): 15-21.
- [20] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [21] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.

- [22] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [23] 程旭, 宋晨, 史金钢, 等. 基于深度学习的通用目标检测研究综述[J]. 电子学报, 2021, 49(7): 1428-1438.
- [24] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [25] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]. European conference on computer vision. Springer, Cham, 2016: 21-37.
- [26] 赵文慧, 杨霄, 孟丽洁. 充分利用多尺度特征改进 UNet 实现皮肤病变分割[J]. 电子测量技术, 2022, 45(2): 110-116.
- [27] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015: 234-241.
- [28] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42(8): 2011-2023.
- [29] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020: 11531-11539.
- [30] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. International Conference on Machine Learning, PMLR, 2015: 448-456.
- [31] LU Z, PU H, WANG F, et al. The expressive power of neural networks: a view from the width [C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6232-6240.
- [32] RAMACHANDRAN P, ZOPH B, LE Q V. Searching for activation functions[J]. ArXiv Preprint, 2017, ArXiv:1710.05941.
- [33] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3 [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.
- [34] 彭道刚, 刘薇薇, 威尔江, 等. 基于 CBAM-Res\_UNet 电厂高压蒸汽泄漏检测研究[J]. 电子测量与仪器学报, 2021, 35(12): 206-214.

### 作者简介

张珊, 硕士生, 主要研究方向为图像处理等。

E-mail: 2339750749@qq.com

王文爽, 助理工程师, 主要研究方向为电力通信系统、电力光缆与通信电源运检等。

E-mail: wangwenshuang925@163.com

刘雪峰(通信作者), 教授, 博士, 主要研究方法为图像处理、模式识别等。

E-mail: nina.xf.liu@hotmail.com