

# 一种复杂背景下电气设备红外图像精确分割方法

王琦<sup>1</sup>,张欣唯<sup>2</sup>,童悦<sup>1</sup>,王昱晴<sup>1</sup>,张锦<sup>1</sup>,王咏涛<sup>3</sup>,袁小翠<sup>3</sup>

(1. 中国电力科学研究院有限公司,湖北武汉 430074;2. 华北电力大学(保定),河北保定 071003;3. 南昌工程学院,江西南昌 330099)

**摘要:** 电气设备精确分割是红外图像故障诊断的关键环节,针对主流的语义分割方法对复杂背景下红外图像电气设备分割容易丢失细节问题,提出一种复杂背景下电气设备红外图像精确分割方法。首先,以UNet网络为主体结构改进PSPNet,将UNet网络提取的最高层特征经过多尺度金字塔池化后进行解码;其次,在特征提取主干网络中对每层提取的特征加入卷积注意力机制(Convolutional Block Attention Mechanism, CBAM),从通道和空间2个维度获取图像上下文信息提升网络对电气设备的关注度以增强网络的抗干扰性;最后,构建PSPnet-CBAM-UNet网络,将CBAM注意力机制输出的特征图作为下层特征提取的输入和解码层跳跃连接特征。以复杂背景下电压互感器、电流互感器和断路器三类设备红外图像分割为例测试本文方法有效性,实验结果表明,本文方法对三类电气设备分割交并比和像素准确率均分别大于92%和94%,分割的准确性优于UNet, PSPNet, Deeplabv3+网络,对复杂背景下红外图像电气设备的细节分割更准确。

**关键词:** 红外图像;语义分割;UNet网络;PSPNet;CBAM

**中图分类号:** TP391.41; TM507 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2025.03.012

## An accurate segmentation method for infrared image of electrical equipment under complex environment

WANG Qi<sup>1</sup>, ZHANG Xin-wei<sup>2</sup>, TONG Yue<sup>1</sup>, WANG Yu-qing<sup>1</sup>, ZHANG Jin<sup>1</sup>, WANG Yong-tao<sup>3</sup>, YUAN Xiao-cui<sup>3</sup>

(1. China Electric Power Research Institute Co., Ltd., Wuhan 430074, China;

2. China North China Electric Power University (Baoding), Baoding 071003, China;

3. Nanchang Institute of Technology, Nanchang 330099, China)

**Abstract:** The precise segmentation of electrical equipment is a key step in infrared image fault diagnosis. An accurate segmentation method is proposed for infrared images of electrical equipment in complex backgrounds to address the issue of detail loss with mainstream semantic segmentation methods. Firstly, the PSPNet is improved by incorporating UNet network as the main structure to decode the multi-scale pyramid pooling of features extracted by UNet's top layer. Secondly, Convolutional Block Attention Mechanism (CBAM) is integrated into the feature extraction backbone network to incorporate channel and spatial attention mechanisms for gathering image context information from both dimensions, enhancing the network's focus on electrical equipment to improve its anti-interference capability. Finally, the PSPnet-CBAM-UNet network is constructed, and the features output by the CBAM are used as inputs for lower-level feature extraction and skip-connection features in the decoding layer. The effectiveness of this paper's method is tested with the segmentation of three types of devices in infrared images under complex backgrounds including voltage trans-

**基金项目:** 江西省重大科技研发专项项目(No. 20223AAE02004)资助。

**作者简介:** 王琦(1987-),男,博士,高级工程师,研究方向为高压电气设备故障诊断、状态评价。E-mail:373201386@qq.com

**收稿日期:** 2024-04-29

formers, current transformers, and circuit breakers. Experimental results demonstrate that the proposed method achieves intersection over union and accuracy greater than 92 % and 94 % respectively, and the accuracy of segmentation is better than that of UNet, PSPNet, and Deeplabv3 + networks, and it is more accurate for the detail segmentation of infrared images of electrical equipment in a complex background.

**Keywords:** infrared image; semantic segmentation; UNet network; PSPNet; CBAM

## 1 引言

现代电力系统是社会经济发展的重要支撑,变电站作为电力系统的核心组成部分,承担着能量转换、传输和分配的重要任务。变电站的各种电力设备(如电压互感器、电流互感器、断路器、刀闸等)长期处于工况运行状态老化或者覆盖污渍,从而导致设备的绝缘性能下降或者设备的接触电阻增大,引发设备局部区域过热,给电网的安全稳定运行带来威胁。

近年来红外成像技术在电力系统运维中获得了广泛应用,通过手持红外相机或者将相机搭载在巡检机器人上拍摄电气设备的红外图像,利用智能算法自动检测红外图像中的故障设备。基于红外成像的电气设备故障诊断的方式主要分为两类:一类是根据电气设备的热图像故障特点直接在红外图像中搜索过热区域;如康龙<sup>[1]</sup>利用红外图像灰度直方图确定聚类中心和聚类个数,用遗传算法来确定最优聚类中心,最后用模糊 C 均值来分割过热区域;余成波等<sup>[2]</sup>用 Otsu 阈值分割方法直接分割红外图像,再对二值图像用区域生长法分割过热区域;Zou 等<sup>[3]</sup>以过热图像的像素点为种子点,利用 K 均值聚类将过热区域的像素点聚类,从而分割出过热区域。另一类则是对红外图像中的电气设备进行分割,根据规范<sup>[4]</sup>对分割后的各种不同设备采用不同的准则判断电气设备的运行状态。不同电力设备热症状不同,其检测标准不同,通常采用第二类方法对设备过热状态检测。电气设备准确分割是红外图像故障准确诊断的关键环节,只有准确的分割和识别出红外图像中的电气设备才能根据不同标准对设备的状态进行分析,因此,电气设备分割好坏直接影响故障识别的准确性。

文献中关于电气设备的分割方法主要是基于传统和深度学习分割方法。基于传统的方法主要是根据图像的颜色和纹理利用阈值分割、聚类和区域生长方法等分割出目标,如许志浩等<sup>[5]</sup>直接利用阈值分割法对红外图像分割,将二值图像中较大的连通区域作为三相设备,再根据三相设备的差异检测三相设备的故障。文献<sup>[6]</sup>提出了一种基于模糊推理

的电气设备红外图像分割方法,通过模糊规则对图像的像素点、马氏距离等特征加以推理从而分割出目标像素点。顾亚雄等<sup>[7]</sup>利用简单线性迭代超像素算法对红外电气设备分割。传统的分割方法能够从简单背景图像中分割出目标,但是难以实现对复杂背景多目标图像的分割。

近年来随着机器视觉技术的发展,深度学习已成为电气设备识别及分割的主流算法。目前深度学习在电气设备故障检测中的应用分为两类,一类是 2 阶段模型,即利用目标检测算法识别并框选电气设备目标区域,再对目标区域进行阈值分割。许志浩等<sup>[8]</sup>直接利用 YOLOv3 网络直接检测及识别红外图像中的电流互感器,再利用聚类法对目标框的热点位置分割。谭宇璇等<sup>[9]</sup>将 YOLOv3 作为基础模型,通过对输入图像进行增强,并改进特征提取网络与损失函数,实现了红外变电设备的有效检测。徐小冰等<sup>[10]</sup>利用 Faster-RCNN 网络检测电气设备,再对目标框的图像采用 Otsu 阈值划分方式分离目标。OU 等<sup>[11]</sup>对 Faster R-CNN 的主干网络进行改进,并增加锚点的长宽比,提高了红外变电设备的识别速度和精度。另一类是直接利用语义分割模型对电气设备分割,得到电气设备的轮廓及像素区域,再对像素区域进行分析识别设备过热区域。袁刚等<sup>[12]</sup>利用 Deeplabv3 模型分割电流互感器。邓长征等<sup>[13]</sup>提出了改进的 Deeplabv3 + 网络分割电气设备,利用 CA-MobileNetV3 和 SP-Dense ASPP 分别代替 Xception 和 ASPP 实现特征提取,引入 ECA 注意力机制实现不同层级特征融合,该方法对具有背景干扰的红外图像分割较好。刘赫等<sup>[14]</sup>构建深度残差 UNet 网络对刀闸、断路器等电气设备分割。

以上方法虽然都实现了红外图像电气设备的检测或者分割,但在复杂背景干扰下电气设备细节分割效果欠佳,因此,对复杂背景下的电气设备红外图像分割有待深入研究。结合注意力和多尺度特征融合金字塔池化结构,构建 PSPNet-CBAM-UNet 网络用于复杂背景下电气设备红外图像分割。以 UNet 网络为主体结构改进 PSPnet,并在网络中加入 CBAM 注意力

机制提升网络对电气设备的关注度以增强网络的抗干扰性。在主干特征提取网络的每个特征提取模块加入卷积模块(Convolutional Block Attention Module, CBAM)注意力机制,减少背景区域学习的权重系数,增加目标学习的权重;再对包含特征最丰富的特征层加入多尺度金字塔特征融合网络 PSPNet,提升网络对小目标及细节分割的准确性。

## 2 本文方法

本文以 Unet 网络主体结构改进 PSPNet,保留 PSPNet 网络的多尺度金字塔池化结构,以 Unet 网络的编码和解码结构替换 PSPNet 网络的 CNN 和卷积部分实现特征提取和解码;考虑上下文信息,在 UNet 主干特征提取网络的每层加入 CBAM 注意力机制,减少网络对背景的权重,增加目标权重,从而提高网络的抗干扰性能。

### 2.1 PSPNet

近年来,CNN 已成功应用于图像语义分割中,典型的语义分割网络有 FCN、Segnet、DeepLab 系列

和 UNet 系列等,但是这些网络经过多次卷积和池化等下采样操作,图像的细节信息会逐步丢失,进而影响识别的准确性。PSPNet 网络由 Zhao 等<sup>[15]</sup>首次提出,其网络结构如图 1 所示,PSPNet 网络采用了金字塔池化模块,对语义信息丰富的高维特征层进行了深度解析,使该特征层的全局和局部联系共同作用于最终的预测,可以提高图像的分割质量。

PSPNet 网络由 CNN,PSPnet 多层金字塔和 conv 模块组成,其中 CNN 采用残差网络进行多层特征提取,利用多尺度金字塔池化操作保留更加全面的全局上下文信息和更多维度的图像特征。PSPNet 网络的特色主要是引入了金字塔池化结构,如图 1 中蓝色虚线框所示,它将传统的池化操作分解为  $1 \times 1$ 、 $2 \times 2$ 、 $3 \times 3$ 、 $6 \times 6$  共 4 个池化层,4 个池化层分别将输入的特征图池化到目标尺寸;通过上采样操作将不同的池化结果恢复到输入大小,并将恢复到统一大小的特征层进行级联;将级联后得到的特征层用于分割操作,提升网络的空间分割准确性。

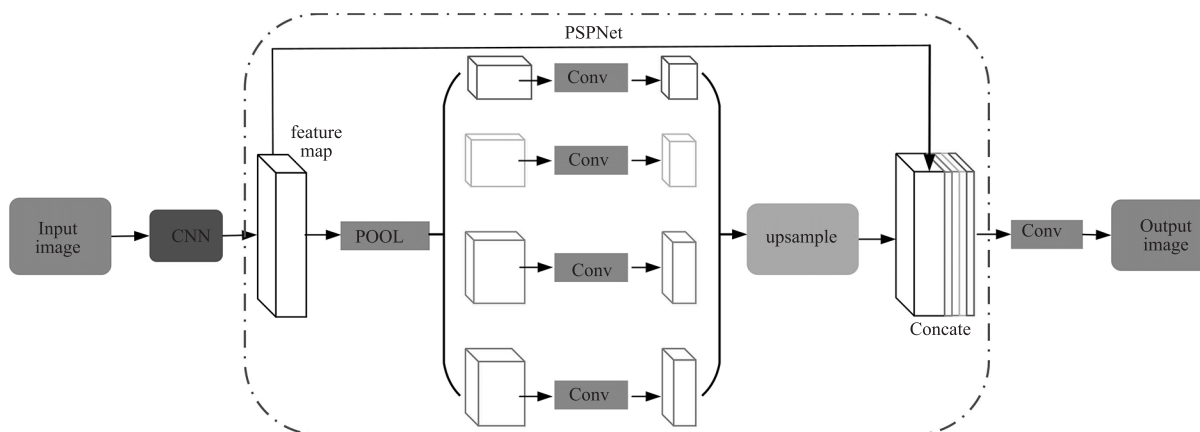


图 1 PSPNet 网络结构

Fig. 1 PSPNet network structure

虽然 PSPNet 使用金字塔池化结构在一定程度上缓解了不同子区域间上下信息丢失问题,但是该网络对分辨率较小的电气设备高层特征图进行解码时没有充分考虑像素之间的关系,忽略了底层空间细节特征对细节分割产生的影响。与可见光图像不同,红外图像的纹理和边界不清晰,颜色简单,目标的细节不容易区分。尤其是红外图像中电气设备处于复杂背景下,干扰因素众多,PSPNet 网络直接用于红外图像电气设备分割将会出现电气设备的细节分割不完整。

### 2.2 UNet 网络

UNet 网络最初设计用于医学图像分割,与 FCN、Segnet、DeepLab 等其他网络相比,该网络在较

少训练样本的情况下具有更高的分割准确性。本文采用 UNet 网络作为主体结构改进 PSPNet 网络。

UNet 网络结构类似 U 型因此被称为 UNet,如图 2 所示,其主体结构分为编码和解码两部分。左侧是编码部分,是网络的主干特征提取网络,每个特征提取模块包括两个  $3 \times 3$  的卷积层和一个  $2 \times 2$  的最大池化层,且采用 Relu 作为激活函数,总计五层特征提取模块,特征通道数经过 4 次下采样之后增加 4 倍。网络右侧是解码部分,是网络的加强特征提取网络,对特征图经过 4 次上采样恢复图像大小;每层特征图先反卷积使特征图通道数减半再进行上采样,采样后特征图与主干特征提取网络的特征图

拼接,再经过两个  $3 \times 3$  的卷积后继续上采样,最后经过一个  $1 \times 1$  的卷积层输出分割图像结果。

本文利用 UNet 网络的编码部分代替 PSPNet 网络中的 CNN 模块实现多尺度特征的提取,利用 UNet 网络的解码部分代替 PSPNet 网络中解码的 Conv 部分,在解码时将编码部分的特征与解码特征拼接,从而更多的保留不同尺度的特征和恢复图像细节。

虽然 UNet 网络架构可以获得不同分辨率的红外图像目标的特征信息,但没有考虑到不同像素类别、通道特征和上下文关联之间存在差异。因此,本文引入注意力机制来进一步改进网络。

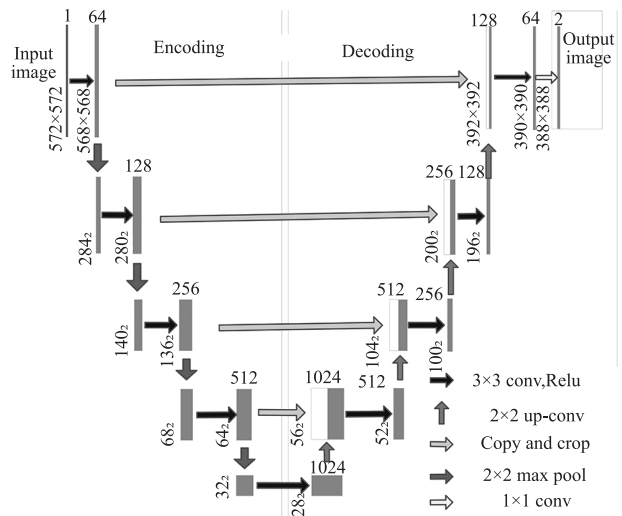


图 2 UNet 网络结构

Fig. 2 UNet network structure

### 2.3 CBAM 注意力机制模块

CBAM<sup>[16]</sup>注意力机制同时结合了通道和空间两个维度的特征信息,CBAM 的整体模块如图 3 所示。通道注意力  $M_c(F)$  与输入特征  $F$  相乘,得到通道注意力特征图  $F'$ ,并作为空间注意力模块的输入,将空间注意力  $M_s(F')$  与  $F'$  相乘,得到 CBAM 输出的特征图  $F''$ ,CBAM 注意力机制的数学表达为:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (1)$$




图 3 CBAM 结构示意图

Fig. 3 CBAM network structure diagram

#### 2.3.1 通道注意力模块

CBAM 的通道注意力模块结构如图 4 所示,它

对输入特征图  $F$  分别做平均池化和最大池化得到两个通道的特征图,将这两特征图分别输入到多层感知器(Multilayer Perceptron, MLP)中,之后将两特征图进行像素的相加操作,经过激活函数 Sigmoid 得到通道权重  $M_c(F)$ ,  $M_c(F)$  的计算表示为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (2)$$

其中,  $\sigma$  为 sigmoid 函数;MLP 为多层感知器;AvgPool 为平均池化;MaxPool 为最大池化。




图 4 通道注意力模块结构示意图

Fig. 4 Schematic diagram of channel attention module

#### 2.3.2 空间注意力模块

CBAM 的空间注意力模块结构如图 5 所示,将输入特征图分别通过最大池化和平均池化,并将池化后的特征图拼接,再通过卷积操作将通道数恢复为初始输入特征图的通道数,最后经过激活函数 Sigmoid 得到空间权重  $M_s(F')$ ,  $M_s(F')$  的计算表示为:

$$M_s(F') = \sigma(f([\text{AvgPool}(F'), \text{MaxPool}(F')])) \quad (3)$$

其中,  $f$  表示卷积运算,  $[\ ]$  表示特征拼接。




图 5 空间注意力模块示意图

Fig. 5 Schematic diagram of spatial attention module

本文将 CBAM 注意力机制与 UNet 网络中每层特征提取相结合,将每层提取的特征输入到 CBAM 模块中,CBAM 输出的特征图作为下层特征提取的输入和解码部分的跳跃连接。通过对特征提取模块添加 CBAM 注意力机制,对各卷积层中的卷积单元调整权重来抑制不重要的背景特征信息,使网络重点关注红外图像中电气设备区域的特征,减少背景区域学习的权重系数。

#### 2.4 本文网络结构

结合多尺度空间特征与注意力机制,构建 PSPNet-CBAM-UNet 网络,其结构如图 6 所示。网络分为编码和解码部分,编码部分由多层特征提取和

CBAM 结构组成,在每层提取的特征图后加入一个 CBAM 注意力机制模块对卷积层中的卷积单元调整权重,来抑制不重要的背景特征信息,经过注意力机制调整后的特征图作为下层的输入和跳跃连接的特征图。通过  $2 \times 2$  的最大池化操作对上层输入的特征进行下采样,并且通过卷积将特征通道加倍。网络总计 5 层特征提取模块,且特征通道数分别是 64,128,256,512,1024。将包含语义信息最丰富的高维特征 Layer 5 传入 PSPNet 模块得到 Layer 6。解码器对 Layer 6 特征进行逐层解码,先通过  $2 \times 2$  的转置卷积进行上采样,压缩特征通道数量,再将压缩后的特征与编码器中具有通道数相同的特征进行拼接,对拼接后的特征卷积减少特征通道数量,使输出解码模块的特征通道数量与同层次的编码层的特征图通道数量一致,逐层解码,最后通过  $1 \times 1$  卷积输出预测结果。

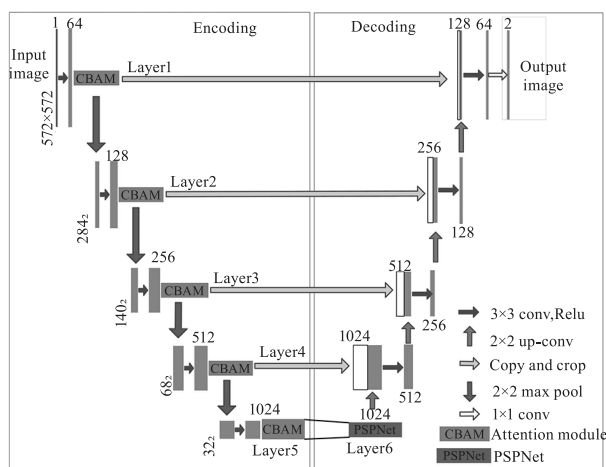


图 6 PSPNet-CBAM-UNet 网络结构

Fig.6 PSPNet-CBAM-UNet network structure

### 3 实验分析与讨论

#### 3.1 网络训练

本文实验在 Windows 系统 Pytorch 框架下进行,实验所用计算机硬件配置为:13<sup>th</sup> Gen Intel(R) Core (TM) i7 - 13700KF@ 3.40 GHz CPU;显卡:NVIDIA GeForce RTX 4070 Ti;内存 RAM 64GB。实验数据来源于国网某电力公司的非公开电气设备红外图像,包含的电气设备有断路器、电压互感器和电流互感器,样本数据集共 914 张,经旋转和缩放增强后样本扩充为 1828 张图像,三类样本的数量分别是 584,592,652 张。用 labelme 工具将图像中的电气设备进行标注,分别将电流互感器、电压互感器、断路器标记为 CT,PT,QF。这三类设备的整体结构非常相似,都具有柱状结构,其主要区别在接头柱状区

域,为了准确识别三类设备,结合视觉显著特征,对三类样本标记时标记出其接头区域和连接的柱状区域,三类设备的样本原图和样本标签如图 7 所示,三类设备最大区别在于接头区域,如绿色矩形框所示。三类设备在接头区域最容易产生过热,因此,准确识别和分割接头区域是实现热点故障识别的关键。

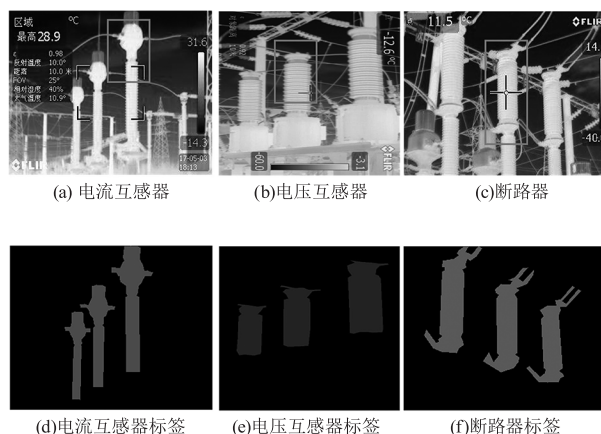


图 7 三类电气设备原图及样本标签

Fig.7 The original images and labels of three kinds of equipment

将标签样本数据集按照训练集、验证集和测试集按 7:1.5:1.5 的比例随机分配。网络训练的损失函数为交叉熵,训练轮次设置为 300 epoch,优化算法为 Adam,初始 batchsize 设为 8,初始学习率为 0.0001,前 50 epoch 的冻结训练。网络训练采用交叉熵为损失函数,定义如下:

$$E = \sum_c \omega_c \log_{10}(P_c(z_i)) \quad (4)$$

式中, $\omega_c$  为类别  $c$  的损失权重; $p_c(z_i)$  为像素  $z_i$  属于真实类别  $c$  的概率。训练过程中损失曲线 loss 值如图 8 所示,epoch 为 200 左右时 loss 趋于收敛,表明本文设计网络利用电气设备红外图像数据集训练能使模型快速收敛。

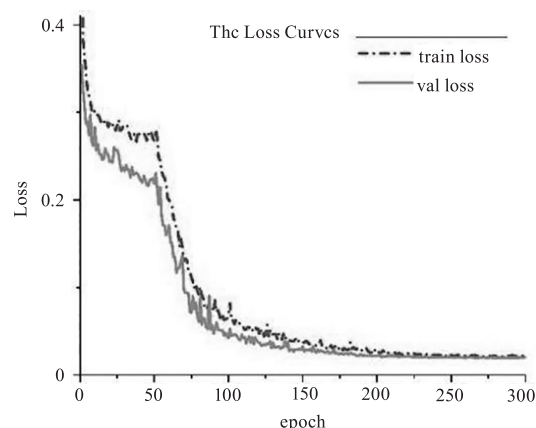


图 8 模型训练损失曲线

Fig.8 The loss curves of our network training

### 3.2 评价指标

利用交并比 (Intersection Over Union, IoU) 和像素准确率 (Pixel Accuracy, AP) 来量化及评估本文方法对电气设备设备的分割效果。IoU 和 AP 分别用来表示分割结果与真实值之间的重合程度和分类正确的像素点数与所有的像素点数的比例。两者定义如下:

$$IoU = \frac{\text{area}(\text{SegmentaionArea} \cap \text{GroundTruthArea})}{\text{area}(\text{SegmentaionArea} \cup \text{GroundTruthArea})} \quad (5)$$

$$PA = \frac{TP}{\text{Total of pixel}} \quad (6)$$

其中,  $TP$  表示正确分类的像素点数量。

### 3.3 不同分割算法性能比较

将本文方法与 UNet, PSPNet, CBAM-UNet, PSPNet-UNet, Deeplabv3 + 方法进行对比, 其中 CBAM-UNet 是本文所述网络中去除了 PSPNet 模块的网络, PSPNet-UNet 是本文网络去除注意力机制后的网络。六种网络训练样本相同, 各模型训练方式和参数保持一致。六种模型对测试样本的分割的准确性如表 1 所示。

表 1 不同模型对电气设备分割的准确性

Tab. 1 The segmentation accuracy of electrical equipment using different models

Method	PT		CT		QF	
	IoU/%	PA/%	IoU/%	PA/%	IoU/%	PA/%
UNet	86	93.3	90.5	93.5	85.1	88
PSPNet	85.1	91.2	86	92.5	84.5	86.7
PSPNet-UNet	87.1	92.8	93.6	96.4	86.6	89.3
CBAM-UNet	91	93.1	93.4	97	88.3	90.9
DeepLabV3 +	84.7	89.6	87.8	92.8	80.6	87.6
Our method	92.1	95.8	95.6	97.7	92	94.1

从表 1 可知, UNet 网络对小样本的电气设备分割的准确性优于 Deeplabv3 + 和 PSPNet 网络, UNet 网络的对 PT, CT, QF 三类电气设备分割的 IoU 和 PA 均高于 Deeplabv3 + 和 PSPNet 网络。在 UNet 网络中分别加入 PSPNet 和 CBAM 注意力机制后, 网络的分割准确性都略高于 UNet 网络, 可见单独融合多尺度金字塔池化模块和注意力机制后均能提升网络对电气设备分割的准确。本文以 UNet 网络为主体架构, 改进 PSPNet 并加入 CBAM 注意力机制后网络的分割性能明显提升。相比于 UNet 网络, 本文对 PT, CT, QF 三类样本分割的 IoU 分别提升了 6.1%、2.5%、7.1%, PA 分

别提升了 2.5%、4.2%、6.1%。

在红外图像电气设备故障检测中需要特别关注电气设备的接头区域, 这些部位是电流的流入和流出区域, 接头区域相比于其他部位更容易过热。如电压互感器与高压线接触部位、流入与流出电流互感器接头部位和断路器的接头区域等。在基于红外图像的设备过热检测时, 除了要准确分割出电气设备外, 还需要精确分割其接头细节区域以避免故障漏检。

以图 9 三类设备的红外图像分割为例说明不同网络对设备分割效果, 6 种方法对三种图像的分割结果如图 10 所示。




图 9 不同背景下的电气设备红外图像及签图

Fig. 9 The electrical equipment of infrared images under different background and the ground truth image of the electrical equipment

从图 10 中不同网络对复杂背景下的 PT, CT, QF 三类电气设备分割的结果可知, 在背景干扰下,

六种方法均能分割出设备的主体结构 and 轮廓, 其主要差别是对设备的细节分割。如图 10 中的椭圆区

域标记的接头部位的分割,背景干扰及设备交叠容易导致细节处过分割和漏分割。相比于其他方法,

本文方法不仅准确分割出设备的主体轮廓,对细节分割更准确。




图 10 不同模型对电气设备分割结果

Fig. 10 The segmentation results of electrical equipment using different models

### 3.4 不同注意力机制消融

为了评估注意力机制对网络性能提升效果,将本文网络中的 CBAM 注意力机制与其他广泛应用的注意力机制比较,如 SE、ECA、CA 和 EMA 注意力机制,测试基于不同注意力机制的网络分割性能。具体实施时将本文网络中的 CBAM 模块替换为 SE、ECA、CA 和 EMA 注意力机制构成不同的网络,利用相同的样本对不同注意力机制的网络进行训练,各模型训练时的参数与本文网络训练参数相同。相同测试样本下基于不同注意力机制对电压互感器、电流互感器和断路器三类电气设备的分割的准确性如表 2 所示。从表 2 可见,不同的注意力机制对电气


设备分割的准确性不同,基于 CBAM 注意力机制分割的 PA 和 IoU 值比其他注意力机制的更高,分割结果更准确。

图 11 为三类设备的原图及标签,图 12 是基于不同注意力机制时对图 11 中三类设备分割结果。从图 12 的分割的结果可知,不同注意力机制对设备分割结果差异较大。当红外图像中目标轮廓不清晰,ECA 和 SE 注意力机制对目标漏分割,在背景干扰下,容易将背景错分为目标。相比其他注意力机制,CBAM 注意力机制分割效果更佳,完整分割出电气设备及其接头区域,对设备的细节分割更准确,分割结果更接近真实值。

表 2 不同注意力机制性能比较

Tab. 2 Comparison of performance on different attention module

Method	PT		CT		QF	
	IoU/%	PA/%	IoU/%	PA/%	IoU/%	PA/%
CBAM	92.1	93.8	95.6	97.7	92	94.1
CA	88.5	92.1	90.1	96.7	89.8	90.4
ECA	88.8	92.6	93.1	96.4	90.7	91.1
EMA	90.9	92.6	92.8	96.8	90.8	91.5
SE	88.8	92	93.1	95.7	88.2	89.2




(a) 电气设备红外图像原图

(b) 电气设备标签图

图 11 电气设备红外图像及标签

Fig. 11 The electrical equipment of infrared image and their ground truth



(a) CBAM

(b) CA

(c) ECA

(d) EMA

(e) SE

图 12 不同注意力机制的分割结果比较

Fig. 12 Comparison of segmentation results based on different attention module

#### 4 结 论

研究了红外图像电气设备语义分割方法。针对复杂背景下红外图像电气设备细节分割不准确问题,构建了 PSPNet-CBAM-UNet 网络用于复杂背景下电气设备红外图像分割。以 UNet 网络为基础框架,利用 UNet 网络的编码部分代替 PSPNet 特征提取模块,对 UNet 网络特征提取的最后一层加入多尺度金字塔池化模块后输出特征图,再用 UNet 网络的解码部分对特征图解码;引入 CBAM 注意力机制,在解码部分的每层特征提取模块中融入 CBAM 注意力机制,减少背景干扰重点关注目标区域。以电流互感器、电压互感器和断路器三类电气设备红外图像分割为例验证本文方法,并与 UNet, Deeplabv3+, PSPNet 网络相比,本文方法的分割的 IoU 和 PA 均提升了 3%~6%,对电气设备的细节分割更准确,为热故障识别提供了精确数据源。

#### 参考文献:

- [1] Kang Long. Substation equipment fault diagnosis based on infrared image processing [D]. Beijing: North China Electric Power University, 2016. (in Chinese)  
康龙. 基于红外图像处理的变电站设备故障诊断 [D]. 北京: 华北电力大学, 2016.
- [2] Yu Chengbo, Zeng Liang, Zhang Lin. Multi point fault segmentation of electrical equipment based on OTSU and region growth [J]. Infrared Technology, 2018, 40 (10): 1008 - 1012. (in Chinese)  
余成波, 曾亮, 张林. 基于 OTSU 和区域生长的电气设备多点故障分割 [J]. 红外技术, 2018, 40 (10): 1008 - 1012.
- [3] H Zou, F Huang. A novel intelligent fault diagnosis method for electrical equipment using infrared thermography [J]. Infrared Physics & Technology, 2015, 73: 29 - 35.
- [4] DL/T 664 - 2008, Application rules of infrared diagnosis for live electrical equipment [S]. Beijing: China Electric Power Press, 2008. (in Chinese)



- DL/T 664-2008, 带电设备红外诊断应用规范[S]. 北京: 中国电力出版社, 2008.
- [5] Xū Zhihao, Zheng Shiquan, Kang Bing, et al. Overheat fault identification method for electrical equipment based on three-phase self-searching comparison method[J]. *Infrared Technology*, 2021, 43(11): 1112-1118. (in Chinese)  
许志浩, 郑诗泉, 康兵, 等. 基于三相自搜寻比较法的电气设备过热故障识别方法[J]. *红外技术*, 2021, 43(11): 1112-1118.
- [6] Zeng Shuiling, Tang Minzhi. Infrared image segmentation for electrical equipment based on fuzzy inference[J]. *Infrared Technology*, 2023, 45(5): 446-454. (in Chinese)  
曾水玲, 唐敏之. 基于模糊推理的电气设备红外图像分割[J]. *红外技术*, 2023, 45(5): 446-454.
- [7] Gu Yaxiong, Feng Shuangshuang. A holistic segmentation method for faulty electrical equipment under complex background[J]. *Infrared Technology*, 2023, 45(5): 455-462. (in Chinese)  
顾亚雄, 冯爽爽. 一种复杂背景下的故障电气设备整体分割方法[J]. *红外技术*, 2023, 45(5): 455-462.
- [8] Xū Zhihao, Luo Lü, Yuan Gang, et al. Thermal fault identification method of current transformer based on hotspot position classification[J]. *Laser & Infrared*, 2021, 51(12): 1628-1634. (in Chinese)  
许志浩, 罗吕, 袁刚, 等. 基于热点位置分类的电流互感器发热故障判别方法[J]. *激光与红外*, 2021, 51(12): 1628-1634.
- [9] Tan Yuxuan, Fan Shaosheng. Infrared thermal image recognition of substation equipment based on image enhancement and deep learning[J]. *Proceedings of the CSEE*, 2021, 41(23): 7990-7998. (in Chinese)  
谭宇璇, 樊绍胜. 基于图像增强与深度学习的变电设备红外热像识别方法[J]. *中国电机工程学报*, 2021, 41(23): 7990-7998.
- [10] Xū Xiaobing, Yuan Jing, Liao Yanqun, et al. Autonomous diagnosis method for defects of cable accessories based on faster RCNN and mean-shift algorithm by infrared images[J]. *High Voltage Engineering*, 2020, 46(9): 3070-3080. (in Chinese)  
徐小冰, 袁婧, 廖雁群, 等. 基于 Faster RCNN 与 Mean-Shift 的电缆附件缺陷红外图像自动诊断方法[J]. *高压技术*, 2020, 46(9): 3070-3080
- [11] Ou J, Wang J, Xue J, et al. Infrared image target detection of substation electrical equipment using an improved faster R-CNN[J]. *IEEE Transactions on Power Delivery*, 2023, 38(1): 387-396.
- [12] Yuan Gang, Xu Zhihao, Kang Bing, et al. DeepLabv3 + Network-based infrared image segmentation method for current transformer[J]. *Infrared Technology*, 2021, 43(11): 1127-1134. (in Chinese)  
袁刚, 许志浩, 康兵, 等. 基于 DeepLabv3 + 网络的电流互感器红外图像分割方法[J]. *红外技术*, 2021, 43(11): 1127-1134.
- [13] Deng Changzheng, Luo Bingjie, Fu Tian, et al. Infrared image segmentation algorithm of power equipment based on improved DeepLabv3 + algorithm[J/OL]. *Infrared Technology*, 2024, 1-8, [2024-04-11]. <http://kns.cnki.net/kcms/detail/53.1053.TN.20240110.1620.002.html>. (in Chinese)  
邓长征, 骆冰洁, 付添, 等. 基于改进 DeepLabV3 + 的电力设备红外图像分割算法[J/OL]. *红外技术*, 2024, 1-8, [2024-04-11]. <http://kns.cnki.net/kcms/detail/53.1053.TN.20240110.1620.002.htm>
- [14] Liu He, Zhao Tiancheng, Liu Junbo, et al. Deep residual UNet network-based infrared image segmentation method for electrical equipment[J]. *Infrared Technology*, 2022, 44(12): 1351-1357. (in Chinese)  
刘赫, 赵天成, 刘俊博, 等. 基于深度残差 UNet 网络的电气设备红外图像分割方法[J]. *红外技术*, 2022, 44(12): 1351-1357.
- [15] H Zhao, J Shi, X Qi, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6230-6239.
- [16] S Woo, J Park, J Y. Lee, et al. CBAM: Convolutional block attention module[C]//In Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.