

基于部件分割和区域温度提取的电力设备异常识别算法

占宇颀, 侯慧娟, 盛戈皞, 江秀臣

(上海交通大学 电气工程学院, 上海 200240)

摘要:为了提高电力设备红外图像中部件温度分析与加热故障检测的准确性,提出一种融合实例分割与温度矩阵分析的电力设备热状态检测方法。该方法以红外成像技术获取的图像及对应温度矩阵为数据基础,构建基于目标检测与实例分割的电力设备部件分割模型。在主干网络中引入全局上下文网络(GCNet),以增强特征的上下文建模能力;在颈部网络中引入多维可变卷积(ODConv)结构,以降低特征冗余并提升跨尺度特征融合效果。基于分割得到的部件区域,提取对应温度矩阵数据,对部件温度分布特征进行统计分析,并结合电力设备故障温度判据实现对设备加热故障的初步诊断。实验结果表明,改进模型在红外电力设备数据集上的平均精度均值(mAP)结果中,mAP@0.5(M)和mAP@0.5:0.95(M)分别达到89.7%和57.9%,较基准模型分别提升2.6%和3.6%。在温度分布分析中,部件温度标准差降低2.58,峰度提高3.4,温度数据集中程度显著增强。所提方法能够有效提升红外图像中电力设备故障检测与温度分析的准确性,为设备状态监测与故障诊断提供可靠依据。

关键词:电力设备;红外图像;部件分割;上下文机制;自适应卷积;温度监测

DOI:10.15938/j.emc.2026.01.002

中图分类号:TM83

文献标志码:A

文章编号:1007-449X(2026)01-0011-13

Power equipment fault detection algorithm using component segmentation and localized thermal analysis

ZHAN Yujie, HOU Huijuan, SHENG Gehao, JIANG Xiuchen

(School of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract:To improve the accuracy of component temperature analysis and heating fault detection in infrared images of power equipment, a thermal state detection method integrating instance segmentation and temperature matrix analysis was proposed. Infrared images and corresponding temperature matrices were used as the data source, and a power equipment component segmentation model based on object detection and instance segmentation was constructed. A global context network (GCNet) was introduced into the backbone network to enhance contextual feature modeling, while an omni-dimensional dynamic convolution (ODConv) structure was incorporated into the neck network to reduce feature redundancy and improve multi-scale feature fusion. Based on the segmented component regions, the corresponding temperature matrix data were extracted, and statistical analysis of component temperature distribution was conducted. Combined with fault temperature criteria of power equipment, preliminary diagnosis of heating faults

收稿日期: 2025-08-27

作者简介: 占宇颀(1999—),男,硕士研究生,研究方向为电力设备红外图像处理和故障诊断;

侯慧娟(1984—),女,博士,助理研究员,研究方向为输变电设备状态监测与数据处理;

盛戈皞(1974—),男,博士,研究员,研究方向为电力设备状态监测与智能化;

江秀臣(1965—),男,博士,教授,博士生导师,研究方向为电力设备在线监测。

通信作者: 侯慧娟

was achieved. Experimental results show that the improved model achieves mean average precision values of 89.7% for mean average precision (mAP), $\text{mAP}@0.5(\text{M})$ and 57.9% for $\text{mAP}@0.5:0.95(\text{M})$, representing improvements of 2.6% and 3.6%, respectively, compared with the baseline model. In temperature distribution analysis, the standard deviation of component temperature is reduced by 2.58, and kurtosis is increased by 3.4, indicating a higher degree of temperature data concentration. These results demonstrate that the proposed method effectively improves fault detection and temperature analysis accuracy in infrared images of power equipment, providing reliable support for equipment condition monitoring and fault diagnosis.

Keywords: electrical equipment; infrared images; component segmentation; context mechanism; adaptive convolution; temperature monitoring

0 引言

电力设备的状态监测和故障检测一直以来都是电力行业的重要课题。状态监测的对象种类繁多,涵盖声、光、电、热等多个物理维度,其中电力设备的图像作为最直观和有效的数据,成为最热门的研究对象之一。目前,针对电力设备图像的研究方向主要是电气设备部件的识别,其中基于可见光和红外成像的视觉检测方法是识别和故障诊断电气设备的两种常用方法^[1]。红外成像技术作为一种有效的非侵入式工具,可以在不需要停电的情况下检测设备的热状态,对诊断电气设备的过热故障具有重要作用,已成为评估此类故障的重要诊断工具^[2]。然而,在人工智能出现之前,红外图像的处理往往依靠专家人工诊断。尽管技术进步显著,但单纯依赖人工检测的方法效率低下,而且往往难以保证准确性和效率^[3]。此外,现有红外热成像仪捕获的红外图像通常存在空间分辨率低、清晰度差等缺点^[4],这导致红外图像识别和处理任务相对可见光图像更加困难。

近几十年来,电网的智能化水平显著提高,不仅具备了更加复杂的结构和更高的运行效率,而且在数据处理能力上也取得了显著的提升。智能巡检技术大大增加了科研人员能够获取的数据,为新一代深度学习技术应用于智能电网提供了极大的帮助^[5-6]。因此,利用计算机视觉检测技术从大量图像数据中识别电气设备和诊断加热故障成为一个热点课题^[7]。深度学习和机器视觉技术的快速发展使得研究人员能够将视觉检测技术应用于大量的电力巡检图像中^[8]。这些技术不仅提升了检测的准确性,还极大地提高了工作效率,减少了人工巡检的负担,同时有助于电气设备的识别和表面缺陷检测,

实现智能化识别和分析^[9]。同时,它们还为电网的故障预测和维护决策提供了科学依据,从而促进了智能电网的进一步发展。

自 Girshick 等在 2014 年提出卷积神经网络 (convolutional neural network, CNN) 算法以来,主流的深度学习算法如快速区域卷积神经网络^[10] (faster region-based convolutional neural networks, Faster R-CNN)、单阶段多框检测器 (single shot multibox detector, SSD) 和一次性目标检测算法^[11] (you only look once, YOLO) 相继出现。Faster R-CNN 通过引入区域提议网络 (region proposal network, RPN) 有效提高了目标检测的速度和精度,广泛应用于自动驾驶、智能安防等领域。YOLO 则通过将目标检测问题转化为回归问题,显著提高了检测速度,成为实时检测系统中的主流选择,广泛应用于无人机、机器人视觉等领域。SSD 结合了多尺度特征的优点,优化了小物体检测能力,在工业自动化、视频监控等领域表现出色。在深度学习算法发展的背景下,电力设备的故障诊断方法也从传统图像处理转向深度学习,近年来不少相关研究聚焦于此。顾超越等^[12]利用深度残差网络和金字塔多特征尺度融合手段改进 Faster R-CNN 检测模型,对无人机巡检架空线路销钉缺陷进行检测,得到了优于传统检测方法的效果。文献[13]改进了 Faster R-CNN 并应用图像分割技术实现了绝缘子的定位和缺陷的检测。

众多神经网络算法中,YOLO 模型是目标检测任务中最热门的算法之一。它是一种经典的单阶段检测算法,其独特的单次检测机制将目标检测视为一个单一的回归问题,直接从图像像素预测边界框坐标和类别概率,大大提高了处理速度,实现了需要快速响应的应用中的实时目标检测。此外,该模型在处理噪声高、对比度低的红外图像时表现出色,通

过其强大的特征学习能力,有效识别出图像中的目标物体。许多改进版本的 YOLO 在电力设备检测中取得了显著成果。王凌云等^[14]在 YOLOX 算法中引入 Ghostnet 和坐标注意力模块,相比已有模型具有体积小、实时性好、精度高的特点。王媛彬等^[15]融合 Triple 注意力机制至特征提取网络,在轻量化的同时高效完成红外图像目标检测的任务。刘闽等^[16]提出一种基于重参数化 YOLOv5 的输电线路缺陷边缘智能检测方法,推理速度和模型大小获得明显优化。郝帅等^[17]将双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)结构引入 Neck 中,使多尺度特征有效融合。周华平等^[18]构建并行池化模块与修正自蒸馏框架,提高模型在前视红外(forward looking infrared, FLIR)数据集上的表现。然而,YOLOv5 的传统模式主要进行目标识别,尚未充分利用红外图像中部件的边缘和数据,尤其在部件实例分割方面的研究相对较少。目前的研究中,比较多应用于实例分割任务的模型有掩码区域卷积神经网络(mask region-based convolutional neural network, Mask R-CNN)、DeepLabv3+、全景特征金字塔网络(panoptic feature pyramid network, Panoptic FPN)等,这些模型具有不错的精度,但是因为其二阶段检测的特点,在运算速度和资源消耗上并不占优势。考虑到实际应用,本文使用 YOLOv5 的变体分割模型完成分割任务,并与相关模型进行对比。

本文使用融合全局上下文网络(global context network, GCNet)与多维可变卷积(omni-dimensional dynamic convolution, ODConv)的改进 YOLOv5 segment 分割模型对套管等部件进行实例分割的基础上,利用红外图像本身的温度矩阵,将检测结果与温度矩阵配合,得到部件的温度分布,结合相关文件中对部件温度故障的定义,给出更准确的定量参考,对红外故障诊断的智能诊断具有一定帮助。

1 电力设备红外图像分割算法及改进原理

1.1 红外图像分割算法框架

YOLOv5 是目前最主流的单阶段目标检测模型之一,因其高效的速度和准确性而备受关注^[19], YOLOv5 提供了带实例分割功能的扩展版本,将模型的能力从传统的目标检测拓展到实例分割任务,这意味着,对于指定的图片,模型能够识别出不同物体的具体轮廓和形状,从而在更细致的层面上进行分析和处理。

与 YOLOv5 目标检测模型类似, YOLOv5 segment 模型含有主干网络 Backbone、颈部网络 Neck 和检测头 Segment,如图 1 所示,特征图的尺寸变化已在图中标出。使用 C3 模块作为主干网络,负责提取图像特征在保持高效特征提取能力的同时减少了内存占用和计算开销。颈部采用路径聚合网络(path aggregation network, PANet)帮助融合不同层次的特征,尤其是在处理多尺度目标时, PANet 提供了更精准的特征信息,对检测和分割不同大小的物体尤为重要。检测头是 YOLOv5 segment 模型与原版改动较多的部分,原目标检测模型的检测头输出锚框对应的坐标、类别概率、前景概率并计算矩形框损失、类别损失和置信度损失,二分割模型增加了一个掩码预测分支,除了原有的分类和边界框预测之外,还能够生成物体的二值分割掩码,以便于对物体的具体轮廓进行像素级的分类。在损失函数定义上二者也略有不同, segment 模型使用分割损失,计算分割掩码与真实分割掩码之间的差异,通常会使用 Dice 损失(DiceLoss)表示,即

$$\text{DiceLoss} = 1 - \frac{2 \sum p_i g_i}{\sum p_i^2 + \sum g_i^2} \quad (1)$$

式中: p_i 为预测概率结果,表示像素 i 属于前景的概率; g_i 为真实标签,取值为 1 时为前景,取值为 0 为背景。

也有部分算法使用交叉熵损失,即

$$\text{Loss} = - \frac{1}{n} \sum_{i=1}^n [g_i \log(p_i) + (1 - g_i) \log(1 - p_i)] \quad (2)$$

除此之外, segment 模型放弃了置信度损失,原因是其不需要判断物体的存在与否,只需关注每个像素的分类。二者输出的结果也有一定差异,目标检测的输出是边界框和类别,而分割模型的输出是每个像素的类别。

1.2 红外图像分割算法的 Backbone 改进

本文模型对 Backbone 部分的改进主要针对 C3 模块。C3 模块将特征图分为两条线路,其中一张经过卷积操作后再经过 n 个 Bottleneck 模块,与另一张经过卷积操作的特征图拼接,最后通过卷积调整维度输出。

Bottleneck 的主要结构为残差连接,其多层卷积的设计使网络可以学习到更为复杂和丰富的特征表示,提升模型性能。C3 模块和 Bottleneck 模块的结构如图 2 所示。




图 1 YOLOv5 segment 模型
Fig.1 YOLOv5 segment model




图 2 C3 和 Bottleneck 模块结构图

Fig.2 Module structure diagram of C3 and Bottleneck

GCNet 综合了非局部神经网络 (non-local neural network, NL) 和通道注意力模块 (squeeze-excitation, SE)。前者通过自注意力机制建模像素对关系,后者用全局上下文对不同通道进行权重值标定,以调整通道依赖^[20]。简化的 NL、SE 和 GCNet 的结构如图 3 所示。传统 NL 模块通过计算当前位置与全局的关系来捕获更大范围的空间关系,一定程度上解决了卷积操作感受视野受限的问题,但在每个位置学习几乎一致的注意力特征图,造成了计算资源的大量浪费。SE 模块着眼于通道间的差异,通过全局平均池化和两次全连接操作生成每个通道的权重掩码,对每个通道的重要性进行重新标定,即

$$\text{Weight} = \sigma \{ W_2 \delta [W_1 \text{GlobalAvgPool}(x)] \} \quad (3)$$

式中:GlobalAvgPool(x)是对输入特征图 x 进行全局平均池化; W_1 和 W_2 是全连接层的权重矩阵; δ 为 ReLU 激活函数; σ 为 Sigmoid 激活函数,输出权重范围在 $[0,1]$ 之间;Weight 是通道权重,通过 SE 模块计算得出。




图 3 三种模块结构示意图

Fig.3 Schematic diagrams of three module structures

GCNet 兼顾了二者的优势:Context Modeling 借鉴 NL 模块,优化了其对于 query 的学习依赖,采用注意力池化生成上下文特征,具体来说,给定输入特征图,通过 1×1 卷积操作生成 query、key、value 这 3 个特征映射,计为 Q, K, V , 根据下式计算上下文权重:

$$\text{Attention} = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right). \quad (4)$$

式中 d_k 为 key 的维度。

Transform 参考 SE 模块,输出处理后特征图各个通道的权重掩码。因此 GCNet 有效对全局上下文建模,同时一定程度上也做到了轻量化。GCNet 中的上下文特征生成可通过下式表示:

$$\text{Context} = \text{Attention}(x)x. \quad (5)$$

式中: $\text{Attention}(x)$ 为模型生成的关于特征图 x 的上下文权重,直接与 x 相乘,提高特征图的特征表达能力;Context 是 GCNet 生成的上下文特征。

本文将 GCNet 引入 C3 模块,将其置于纯卷积支路上,如图 4 所示。具体实现包括以下步骤:首先,输入特征图通过卷积层提取局部特征,随后进入 GCNet 模块。在 GCNet 内部,上下文建模部分通过注意力机制生成全局上下文特征,这些特征能够捕捉特征图中不同位置之间的依赖关系。接着,Transform 模块通过全局平均池化和全连接层生成通道权重,对特征图的通道进行自适应加权,从而突出重要通道的特征。




图 4 引入 GCNet 的 C3 模块

Fig. 4 C3 module with introduction of GCNet

通过在 C3 模块中引入 GCNet, YOLOv5 能够在分割任务中更好地处理复杂场景。实验验证表明,这种改进在本实验的红外数据集上取得了不错的性能提升。

1.3 红外图像分割算法的 Neck 改进

本文 Neck 引入全维度动态卷积 (omni-dimensional dynamic convolution, ODCnv), 替换 Neck 部分的传统卷积。传统卷积使用固定的卷积核,这在处理不同输入特征时显得不够灵活,限制了模型的表现。近年来,多位研究人员对动态卷积进行了研究^[21-22],如条件参数化卷积 (conditionally parame-

terized convolution, CondConv) 是最早对动态卷积进行探索的工作之一。该方法在每次前向传播时,利用一组可学习的权重对多个卷积核进行线性加权,动态调整卷积核组合,以适应输入特征的变化。然而,CondConv 在设计上主要关注卷积核的线性组合,忽略了在不同维度 (如通道维度、空间维度) 对特征图进行更加精细的加权处理,针对这个问题,ODCnv 在此基础上引入了对空间维度、输入通道维度、输出通道维度的自适应参数^[23],其表达式为

$$y = (\alpha_{\omega 1} \odot \alpha_{f_1} \odot \alpha_{c_1} \odot \alpha_{s_1} \odot W_1 + \alpha_{\omega 2} \odot \alpha_{f_2} \odot \alpha_{c_2} \odot \alpha_{s_2} \odot W_2 + \alpha_{\omega 3} \odot \alpha_{f_3} \odot \alpha_{c_3} \odot \alpha_{s_3} \odot W_3 + \alpha_{\omega 4} \odot \alpha_{f_4} \odot \alpha_{c_4} \odot \alpha_{s_4} \odot W_4) * x_o. \quad (6)$$

式中: x, y 分别为输入输出特征图; $\alpha_{\omega i} \in \mathbf{R}$, 对每一个卷积核 W_i 赋予不同权重; $\alpha_{f_i} \in \mathbf{R}^{\text{out}}$, 在特定卷积核下对每一个输出通道的特征图赋予不同权重; $\alpha_{c_i} \in \mathbf{R}^{\text{in}}$ 同理, 对输入通道进行处理; $\alpha_{s_i} \in \mathbf{R}^{k \times k}$, 对卷积核每一个滤波器赋予不同权重。它们分别为卷积核 W_i 、输出通道、输入通道、卷积核滤波器的关注参数,并以不同的方式进行不同维度的乘法运算,并最终作用在输入特征图上。ODCnv 卷积相比于常规卷积,计算资源需求略有提高。对常规卷积,不考虑偏置,有

$$M\text{Adds} = h\omega k^2 c_{\text{in}} c_{\text{out}}. \quad (7)$$

对于 ODCnv, 除正常卷积之外的额外计算量为

$$M\text{Adds}_{\text{extra}} = h\omega c_{\text{in}} + \frac{c_{\text{in}}(2c_{\text{in}} + c_{\text{out}} + k^2 + n)}{r} + k^2 c_{\text{in}}(1 + c_{\text{out}} + 2nc_{\text{out}}). \quad (8)$$

式中: h, ω 为特征图的长宽; k 为卷积核尺寸; c_{in} 与 c_{out} 为输入输出通道数; n 为滤波器数量; r 为归约系数,通常取 4、8、16,能一定程度减少计算量。分析两个式子不难发现,增加的计算量相比原有计算量是微不足道的,尤其是在输出通道较大的情况下,二者相差超过 100 倍。事实上,额外计算量主要来源于对卷积核的各项处理,与特征图本身的尺寸联系较小。

尽管 ODCnv 的计算复杂度略有提升,实验结果表明,这种额外的计算开销是值得的。通过对卷积核的多维度动态调整,ODCnv 能够显著增强模型的表达能力,从而在多个计算机视觉任务中展现出优异的性能。这种技术在处理复杂特征关系时尤为有效,尤其是在需要对空间和通道信息进行联合建模的任务中,ODCnv 能够更好地捕捉到全局和

局部的信息交互。

1.4 算法改进小结

电力设备的红外图像异常检测任务具有目标尺寸差异大、边缘模糊、背景噪声强等特点,这使得模型不仅要具备较强的全局感知能力,还需能在局部区域内自适应地提取细粒度特征。传统目标检测算法多通过矩形检测框提取区域信息,但在电力设备场景中,检测框往往包含大量无关背景像素,导致温度数据分布偏差、统计特征失真,难以准确反映元件真实热状态。为解决这一问题,本文选用实例分割模型替代传统目标检测模型,以获得像素级的部件区域划分,使后续温度提取更加精确可靠。

电力设备红外图像中目标边界模糊、灰度梯度细微、背景复杂,对模型的特征提取与跨尺度表达能力提出了更高要求。针对这一问题,本文在主干网络中引入了 GCNet 全局上下文模块,在颈部网络中引入了 ODConv 全维动态卷积模块。GCNet 模块能够在特征提取阶段捕获跨区域的长程依赖关系,从整体上理解红外热场的空间分布规律,使模型在分割时具备更强的上下文语义建模能力。其引入显著增强了模型对电力设备中复杂热模式(如温度梯度、热扩散路径)的感知,有效提升了边缘模糊部件的分割精度。ODConv 模块则通过多维度自适应卷积机制,根据输入特征自动调整卷积核权重,实现空间、通道及尺度层面的联合建模。这使得模型能够针对不同尺寸、不同工况下的设备部件灵活调整特征提取方式,强化了模型对局部温度细节与边界形变的刻画能力。

2 电力设备红外图像温度处理

2.1 温度矩阵提取

红外图像的温度数据是其有别于可见光图像的重要参数。在目标识别的基础上将红外图像灰度化,可以通过读取像素灰度值与温宽条,通过灰度值比对返回像素点温度值^[24];对于全图像素点温度值数据,可以进行核密度分析和 K 值聚类,完成对高温部分的提取^[25]。

本文给出一种可行的提取图片温度矩阵的方法。FLIR 红外摄影仪获取的红外图像除图片本身像素信息外,还有许多元数据,可以从各种参数中换算出像素点温度。通过 exiftool 工具,可以提取红外图像的参数,如发射率、大气温度、反射温度、红外窗口温度、红外窗口透射率、相对湿度等。最终的像素

点温度可由下式导出:

$$t = \frac{PB}{\log\left(\frac{PR1}{PR2(\text{raw}_{\text{obj}} + PO)} + PF\right)} - T_0. \quad (9)$$

式中:PB 为与普朗克辐射定律中的波长及常数项相关的参数,用于将辐射率转换为温度;PR1、PR2 为传感器参数,分别对应辐射与温度之间的比例系数和对数尺度因子,用于将红外探测器的输出信号与黑体辐射模型相匹配,体现了设备在不同波段下的灵敏度;PO 为背景辐射偏置项,主要考虑大气及镜头自身辐射造成的基准偏移,它在温度反演时用于补偿非目标区域的背景辐射影响;PF 为辐射强度与温度关系的校正因子,用于补偿传感器非线性响应及系统增益偏差,确保反演温度与实际温度对应关系的线性化;这些参数为红外热像仪在出厂标定阶段确定的常数,主要由探测器响应波段、光学透过率及电子放大特性决定。在相同设备与镜头配置下,这些参数在所有拍摄样本中保持一致,不随场景或工况变化; raw_{obj} 为修正窗口和空气透过率后的物体辐射值,通过读取原始热值,修正各项透过率并减去各项环境辐射后计算得到; $T_0 = 273.15^\circ\text{C}$,将温标转化为摄氏度。这样一来,每一个像素点都有一个温度值与之对应,对于一个 640×480 的 jpg 格式图片,可得到全部 307 200 个点的温度。将温度值按像素坐标可视化,可得到如图 5 所示的结果。其颜色越深表示温度越低,反之亦然。




图5 温度提取可视化

Fig. 5 Temperature extraction visualization

以这种方式可以得到一个 csv 格式文件,其三列分别为 x 、 y 、temp,分别代表像素点的横纵坐标以及温度值。事实上,如果有其他方式获取红外图像每个像素点的位置和信息,也同样适用本文后续的配合方法。

2.2 部件区域分割

YOLOv5 segment 模型在对图片进行预测的同时会生成对应的 txt 标注文件,其格式与数据集一

致,单条标注表达式为

$$\text{Label} = (\text{type } x_1 y_1 x_2 y_2 \cdots x_n y_n)。 \quad (10)$$

式中:第 1 个数字为目标类型,之后每 2 个数字为一组以归一化形式表达顶点坐标, n 个顶点围成一个封闭图形,即为预测的目标像素区域。

为了将各顶点数据对应转化为所围区域,考虑定义一个函数,该函数接受一个点和一系列点集作为输入,判断该点相对于点集的位置关系。若该点位于多边形内部则输出 True,否则输出 False。为了实现这一点,考虑 n 个点顺次连接组成的向量和待处理点,选取其中一组相邻点 A 、 B 和待处理点 C 计算向量积,即

$$\begin{aligned} \mathbf{CA} \times \mathbf{CB} &= (x_A - x_C)(x_B - x_C) - \\ &\quad (y_A - y_C)(y_B - y_C)。 \end{aligned} \quad (11)$$

若 C 与所有向量的向量积均为正或负(可以为 0),则 C 处于每一个向量的左侧或右侧,因此 C 位于所有点围成区域的内部。区域提取示意图如图 6 所示, M 点在所有向量的右侧,因此在多边形内部,而 N 点在 DE 向量的左侧且在其余向量的右侧,因此在多边形外部。这提供了一种判定点和多边形位置关系的算法,遍历图片上的所有像素,即可生成指定多边形内部的所有像素点。为了提高处理效率,可以借助分割区域对应的目标识别框。只需在识别框的坐标范围内选取待检测的参考点,从而显著减少计算量,加快温度数据处理速度。具体实现时,可利用公式快速计算多个点的位置关系,并生成指定多边形内部的所有像素点,从而实现区域提取。




图 6 区域提取示意图

Fig. 6 Schematic diagram of region extraction

2.3 温度数据分析

部件区域掩码与温度数据合并分析可以得到部件区域的温度数据,这些温度值需要一种数据层面有效处理的方法,本文选择高斯核密度估计(kernel density estimation, KDE)方法,获取每个部件区域的代表温度,作为部件温度的参考值。具体步骤为:

1) 过滤掉温度低于预定阈值的区域内点。这些点大多被错误识别为区域内的背景点,去除它们可以提高结果的准确性。阈值可能会随季节变化。

2) 对于每个数据点 x_i , 计算其高斯核函数为

$$K_h(x, x_i) = \frac{1}{\sqrt{2\pi}h} e^{-\frac{(x-x_i)^2}{2h^2}}。 \quad (12)$$

式中 h 是带宽,决定了核的宽度,并影响平滑程度。较小的带宽可能导致平滑较少,有潜在的过拟合,而较大的带宽导致平滑较多,可能导致欠拟合。在实践中,带宽的选择通常与数据的标准差有关。根据斯科特法则,文本选取的带宽为

$$h = \left(\frac{4}{3N}\right)^{\frac{1}{5}} \sigma。 \quad (13)$$

式中 σ 为数据标准差。

3) 平均所有数据点的高斯核函数以获得最终的分布函数。从得到的分布函数中识别其最大值,并使用相应的温度值作为该区域的代表温度,即

$$f(x) = \frac{1}{n} \sum_{i=1}^n K_h(x, x_i)。 \quad (14)$$

3 实验结果

3.1 数据集与实验环境

本实验使用由某省电力公司红外设备拍摄的变电站红外图像作为训练样本与测试样本,图片的分辨率为 640×480 , 包含变压器套管、电流互感器、电压互感器、避雷器、断路器等多种设备,拍摄距离在 $5 \sim 25$ m 范围内,覆盖了设备在不同负载、环境温度及湿度条件下的运行状态,包含正面、侧面及倾斜角度等多角度视图,以增强模型的泛化能力。本文针对数据集进行一定扩充,对原有数据集中 700 张红外图像进行随机的翻转、拉伸、旋转等操作,将数据集扩充至 1 153 张,以提高含标注框的图片在数据集中的比例,标注共有四类,分别为套管(将军帽部分)、避雷器、电流互感器和绝缘子,扩充数据集后含有四类元件的图片数量分别为 199、252、77、93。对数据集使用 labelme 进行多边形掩码描绘,依据设备轮廓及边缘特征逐像素标注,确保掩码区域与设备边界严格对应,以 7:2:1 划分训练集、验证集和测试集。针对不同设备类型,依据《带电设备红外诊断应用规范》等行业标准文件设定温度阈值与参考范围,用于后续过热异常判断。

本文实验主要采用评价指标为精确度 P 、召回率 R 、准确度 $\text{mAP}@0.5(M)$ 与 $\text{mAP}@0.5:0.95(M)$ 等,其计算公式为:

$$P = \frac{T_p}{T_p + F_p} \times 100\% ; \quad (15)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% ; \quad (16)$$

$$mAP = \frac{\sum_{i=1}^N \int_0^1 P_i(R_i) dR}{N} \times 100\% . \quad (17)$$

式中: T_p 为正确识别的样本数; F_p 为被误识别为目标的非目标样本; F_N 为未被识别出的目标样本。在某个阈值下, 某一类目标的精确度 P 和召回率 R 可作为横纵坐标得到一条曲线, 其与横、纵坐标轴围成的区域面积, 对所有类别的面积取平均值, 即为该结果在该阈值下的精确度 mAP , 当阈值为 0.5 时即为 $mAP@0.5$, 在目标检测任务中, 评估的对象为检测框, 在实例分割任务中, 研究对象以掩码区域 (Mask) 为主, 选用的参数为 $mAP@0.5(M)$ 。

本文的实例分割实验在 pytorch 上完成, 其硬件和软件参数如表 1 所示。

表 1 实验环境参数

Table 1 Experimental environment parameters

配置名称	规格或版本
GPU	NVIDIA GeForce RTX 4070
CPU	Intel Core i7 - 13700KF @ 3.40 GHz 16 CPUs
CUDA	12.2
OpenCV	4.8.1

训练参数设置为: 训练轮次 epochs 为 300, 批次 batch-size 为 16, 输入图片大小调整为 640×640 , 优化器为随机梯度下降 (stochastic gradient descent, SGD), 动量大小为默认值 0.937, 学习率衰减策略为余弦退火衰减, 根据初始学习率和最终学习率生成曲线:

$$lr = \frac{1}{2}(lr_0 + lr_1) + \frac{1}{2}(lr_0 - lr_1) [1 + \cos(\frac{t}{T}\pi)] . \quad (18)$$


式中: lr_0 和 lr_1 为初始和最终学习率; t 为当前轮次; T 为最大轮次。与线性下降相比, 余弦退火策略允许学习率在初期保持较高水平, 逐步减小到最低点, 这有助于模型跳出局部最优解, 从而提升全局收敛能力。

3.2 模型优化实验


本文模型通过在 Backbone 和 Neck 网络中分别引入 GCNet 模块和 ODConv 卷积进行优化, 下面通过训练结果分析其优化效果。由于初始预训练权重

可能对不同模型训练速度产生影响, 故选择不使用预训练权重。

在 Backbone 中引入 GCNet 后的 $mAP@0.5(M)$ 及 $mAP@0.5:0.95(M)$ 变化情况如图 7 所示。为了减少短时内轮次上下波动的影响, 使用一个简单的平滑机制, 每个轮次的输出为该轮次与之后 19 个轮次结果平均值, 因此曲线上的最终轮次为 280。



(a) 引入GCNet后的mAP@0.5曲线



(b) 引入GCNet后的mAP@0.5:0.95曲线

图 7 引入 GCNet 后的 mAP 变化情况

Fig. 7 Changes in mAP after introducing GCNet

由图 7 可知, 300 轮次训练之后, $mAP@0.5(M)$ 几乎已经收敛, $mAP@0.5:0.95(M)$ 也已经进入缓慢增长的区间。在整个训练过程中, 结合 GCNet 的 YOLOv5 模型在训练的前中期就展现出了较为明显的性能优势。这种提升主要归功于 GCNet 中的注意力池化机制, 能够更精确地抓取关键像素点的特征信息。此外, GCNet 中通道权重自适应调整功能使得模型能够对不同输入通道做出更为合理的处理, 进而提高了整体的检测效果。300 轮训练之后, 带 GCNet 模块的实例分割模型比原版 YOLOv5 模型的 $mAP@0.5(M)$ 提高了 1.8%, $mAP@0.5:0.95(M)$ 结果提高了 3%, 两项指标均表现出了显著的提升。这进一步表明, 引入 GCNet 后, 模型在不同阈值下的检测能力都得到了增强。这说明, GCNet 的引入对模型性能的提升是有效的。

图 8 为添加 ODConv 替换 Neck 部分传统卷积后的 mAP 变化情况。可以看出, ODConv 同样几乎在整个训练的过程中都表现出了更好的性能。与

Backbone 部分稍有不同的是,卷积模式的改进对最后收敛的结果优化方向有差异,mAP@0.5 (M) 结果及 mAP@0.5:0.95 (M) 结果分别提高了 2.2% 和 1.3%。可能的原因是,Neck 部分主要作用是对 Backbone 提取的特征进行进一步的整合和传递,这里引入 ODConv 可以更灵活地适应不同尺度和形状的目标特征,因此在 50% 阈值下,ODConv 带来的性能提升较为明显,因为它能够在较宽松的检测标准下更好地识别目标。然而,在更严格的阈值下,要求模型对目标进行更精细的分辨和定位,ODConv 的动态卷积机制虽然在提高特征表达能力方面有优势,但其局部性的动态调整可能不足以在更严格的阈值下提升目标细节处理能力。因此,在这个区间 GCNet 更能凸显其优势,尤其是在复杂场景下需要精准捕捉多尺度信息时,GCNet 的全局建模和注意力机制显得更加重要。




图 8 引入 ODConv 后的 mAP 变化情况
Fig.8 Changes in mAP after introducing ODConv

YOLOv5 分割模型与两种改进方法在部分红外图像上的表现如图 9 所示。可以看出,与原模型相比,引入 GCNet 后的网络在左图中防止了错检(将电压互感器检为避雷器),在右图中检出了遗漏的电流互感器;引入 ODConv 后的网络同样在左图防止了错检,同时在中间图片中对原版和 GCNet 版本中漏检的避雷器进行了有效检出。这说明两种改进方式在实际应用中都是有效的。

对常用的分割模型进行性能对比,结果如表 2

所示。可以看出,YOLO 系列相比传统 Mask R-CNN 模型,在性能上有较大优势,这是因为 Mask R-CNN 作为传统两阶段算法,计算和内存开销较大,参数也更多。同时,考虑到后续可能存在的端到端训练的需求,YOLO 模型同样具有更大的优势。在 YOLO 内部各模型的横向对比中,YOLOv5 在精度和资源占用上同时达到了很好的性能,各版本算法中表现最好。而添加了 GCNet 与 ODConv 模块的 YOLOv5 模型在原模型基础上又以较小资源代价获得了不错的精度提升。




图 9 三种模型在部分红外图像上的表现
Fig.9 Performance of three models on selected infrared images

表 2 多种边缘分割算法性能对比
Table 2 Performance comparison of multiple edge segmentation algorithms

算法	精确度/%	召回率/%	mAP@0.5	mAP@0.5:0.95	模型大小/MB
GCNet + ODConv	89.8	82.8	89.7	57.9	15.6
YOLOv5	86.4	84.8	87.1	54.3	14.8
YOLOv8	86.2	80.7	85.5	53.4	23.9
YOLOv9	90.1	77.9	85.4	52.8	18.0
YOLOv10	89.3	77.1	82.5	51.6	18.8
YOLO11	89.1	75.6	81.3	52.0	20.1
Mask R-CNN	—	—	71.6	40.5	43.8

改进模型与原模型的消融实验结果如表 3 所示。通过对比可以发现,本文中两种优化方法都做到了 $mAP@0.5(M)$ 及 $mAP@0.5:0.95(M)$ 的提升,同时引入也有不错的效果。在模型大小上仅有5.4%的小幅提升,而 $mAP@0.5(M)$ 及 $mAP@0.5:0.95(M)$ 分别提升了2.6%和3.6%。

表 3 YOLOv5 改进模型性能对比

Table 3 Comparison of performance between YOLOv5 and improved models

算法	精确度/%	召回率/%	mAP@0.5	mAP@0.5:0.95	模型大小/MB
YOLOv5	86.4	84.8	87.1	54.3	14.8
YOLOv5 + GCNet	89.7	83.0	88.9	57.3	15.5
YOLOv5 + ODConv	89.1	83.1	89.4	55.7	15.0
本文方法	89.8	82.8	89.7	57.9	15.6

在红外图像检测场景中,GCNet 通过全局上下文建模强化了模型对热辐射分布模式的感知能力。该模块通过建立跨区域的长程依赖关系,显著提升了模型对温度场连续特征(如热源扩散梯度、冷热区域过渡边界)的解析能力,这点在热成像中建筑物热桥效应检测任务中尤为重要。而 ODConv 则通过动态卷积核赋予模型多维度自适应特征提取能力,其空间注意力机制能够根据目标区域辐射强度动态调整感受野,这对热斑定位和低温目标捕捉具有关键作用。二者的协同作用体现在:GCNet 构建的全局上下文先验信息为 ODConv 的动态特征提取提供了引导框架,避免自适应卷积在复杂热噪声干扰下产生局部过拟合;同时 ODConv 的细粒度特征补偿机制又能缓解全局建模可能导致的细节信息损失。这种互补性在红外图像多目标场景中体现尤为明显——当处理热源交叠(如密集排布的高温管线)时,GCNet 维持整体热力结构认知,ODConv 则精确区分邻近热源的边缘梯度。值得注意的是,两个模块合并时性能增益略低于理论预期。可能存在以下三方面原因:

1)GCNet 的全局通道注意力与 ODConv 的空间动态卷积在底层均涉及特征重要性重标定机制。GCNet 通过压缩全局空间维度生成通道注意力向量,而 ODConv 通过空间位置动态聚合多维度卷积核参数。二者在特征筛选过程中存在部分功能交集,导致组合后对同一层次特征的重复加权,造成信息过平滑(如高温区域的辐射梯度被过度归一化),

反而弱化了关键热力学特征的判别性。

2)GCNet 的全局上下文建模依赖长程依赖关系构建,而 ODConv 的动态卷积更关注局部特征的适配性优化。当二者并行作用于同一特征层时,全局约束与局部动态调整可能产生优化方向的冲突。GCNet 强调热扩散连续性可能抑制 ODConv 对突发温度骤变的响应灵敏度,导致部分像素级微变特征被双重过滤。

3)在红外图像处理中,GCNet 的全局上下文传播会强化温度场的连续分布特征,而 ODConv 的动态感受野调整则侧重局部辐射强度的突变检测。当处理热源边界模糊目标时,GCNet 的热量梯度传播可能覆盖 ODConv 提取的局部细节模式,造成高频热噪声与有效信号在特征融合阶段的相互抵消。

3.3 温度处理结果

2.2 节中完成了对部件区域范围的提取,部分结果如图 10 所示。对单个识别对象的温度分析结果如图 11 所示。通过 KDE 方法,将离散的诸多温度数据映射到一个连续分布上,读取该曲线的最高点作为该部件的代表温度。作为单部件温度数据,该分布可以较好识别出区域是否存在较多过热点,表现在分布曲线和代表温度上,与相关标准对比,可对过热故障进行初步筛查;除此之外,三相部件的温度也可以作为相间故障初筛的参考标准之一。




图 10 部件区域提取结果

Fig. 10 Results of component area extraction

事实上,由于部件区域固有的温度分布特性,非部件区域温度明显低于部件区域,使用目标检测算法直接分析整个识别框的温度数据并设定阈值,筛选低于阈值的像素点,也可达到类似分割的目的。为体现实例分割相比目标检测结果的优势,本文将

对两者得到的数据结果进行对比。选取的指标为平均温度、标准差和峰度。标准差可以反映数据分散程度,峰度可以描述数据分布的尖锐度,在一般情况下,峰度被定义为四阶累积量除以二阶累积量的平方,它等于四阶中心矩除以概率分布方差的平方减 3。在统计中,样本峰度通常表示为

$$\text{Kurtosis} = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (19)$$




图 11 温度分布数据

Fig. 11 Temperature distribution data

表 4 两种算法对比

算法	平均值	标准差	峰度
YOLOv5	33.84	6.77	0.54
YOLOv5 实例分割	37.18	4.19	3.94

这些优势在实际检测中具有重要意义。实例分割算法减少了背景噪声对温度分析的干扰,避免了因低温区域导致的误判,提高了故障检测的准确性。其更集中的温度分布和更高的峰度值使得温度数据的代表性更强,能够更直观地识别过热区域,为设备过热故障的初步筛查提供了可靠依据。同时,实例分割在相间故障检测中也具有潜力,通过精确的三相部件温度分析,为相间故障的初步筛查提供了更有效的参考标准。实例分割算法不仅提升了温度分析的精度和可靠性,还为电力设备状态监测和故障诊断提供了更高效的技术支持。

4 结 论

本文针对电力设备的状态监测与故障检测,提出一种基于改进 YOLOv5 模型的红外图像实例分割

计算结果如表 4 所示。实例分割的平均温度为 37.18 °C,高于目标检测的 33.84 °C,表明其实例分割有效过滤了低温背景数据,更聚焦于目标部件的温度分布。实例分割的标准差为 4.19,低于目标检测的 6.77,说明其温度数据分布更加集中,离散程度更低,提取精度更高。此外,实例分割的峰度值为 3.94,远高于目标检测的 0.54,表明其温度分布曲线更加尖锐,数据集中性更强,能够更清晰地反映部件区域的温度特性。

及温度处理的方法。主要结论如下:

1) 选用实例分割模型代替传统目标检测模型,用于电力设备红外图像的部件级识别。该方法在像素级别完成部件区域提取,显著减少了背景干扰对温度分析的影响,使提取的温度数据更具代表性和稳定性;

2) 在模型中引入 GCNet 与 ODConv 模块,分别强化全局上下文建模与局部特征自适应能力。GCNet 模块提升了主干网络对热场全局分布与边缘语义的理解,ODConv 模块增强了对多尺度特征与复杂工况的适应性。两者协同作用,在保证计算量无明显增加的前提下,提高了模型的特征表达能力与分割精度,使 mAP@0.5 (M) 提升 2.6%,训练收敛更快;

3) 通过提取红外图像的温度矩阵,将温度数据与 YOLO 分割模型的结果结合,进行部件的温度分布分析。通过这种方法,获得的温度数据分布的标准差降低 2.58,峰度提升 3.4,数据集中程度更高;

4) 实证验证与应用前景实验结果表明,所提出的方法充分利用红外图像中的温度信息,能够有效提升红外图像的故障检测精度及训练速度。

参考文献:

- [1] 刘传洋, 吴一全. 基于红外图像的电力设备识别及发热故障诊断方法研究进展[J]. 中国电机工程学报, 2025, 45(6): 2171.
LIU Chuanyang, WU Yiquan. Research progress of power equipment identification and thermal fault diagnosis based on infrared images[J]. Proceedings of the CSEE, 2025, 45(6): 2171.
- [2] 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.
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.
- [3] 郑含博, 胡钧浩, 李金恒, 等. 基于改进实例分割与深度神经网络温度拟合的电力设备热故障诊断研究[J]. 电机与控制学报, 2025, 29(2): 116.
ZHENG Hanbo, HU Junhao, LI Jinheng, et al. Thermal fault diagnosis of power equipment through improved instance segmentation and deep neural network temperature fitting[J]. Electric Machines and Control, 2025, 29(2): 116.
- [4] 谢庆, 杨天驰, 裴少通, 等. 基于多尺度协作模型的电气设备红外图像超分辨率故障辨识方法[J]. 电工技术学报, 2021, 36(21): 4608.
XIE Qing, YANG Tianchi, PEI Shaotong, et al. Super-resolution identification method of electrical equipment fault based on multi-scale cooperation model[J]. Transactions of China Electrotechnical Society, 2021, 36(21): 4608.
- [5] 戚银城, 武学良, 赵振兵, 等. 嵌入双注意力机制的 Faster R-CNN 航拍输电线路螺栓缺陷检测[J]. 中国图象图形学报, 2021, 26(11): 2594.
QI Yincheng, WU Xueliang, ZHAO Zhenbing, et al. Bolt defect detection for aerial transmission lines using Faster R-CNN with an embedded dual attention mechanism[J]. Journal of Image and Graphics, 2021, 26(11): 2594.
- [6] NGUYEN N V, JENSSEN R, ROVERSO D. Intelligent monitoring and inspection of power line components powered by UAVs and deep learning[J]. IEEE Power and Energy Technology Systems Journal, 2019, 6(1): 11.
- [7] 刘志颖, 缪希仁, 陈静, 等. 电力架空线路巡检可见光图像智能处理研究综述[J]. 电网技术, 2020, 44(3): 1057.
LIU Zhiying, MIAO Xiren, CHEN Jing, et al. Review of visible image intelligent processing for transmission line inspection[J]. Power System Technology, 2020, 44(3): 1057.
- [8] 蒲天骄, 乔骥, 韩笑, 等. 人工智能技术在电力设备运维检修中的研究及应用[J]. 高电压技术, 2020, 46(2): 369.
PU Tianjiao, QIAO Ji, HAN Xiao, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. High Voltage Engineering, 2020, 46(2): 369.
- [9] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. 中国电机工程学报, 2020, 40(17): 5506.
HE Jinghan, LUO Guomin, CHENG Mengxiao, et al. A research review on application of artificial intelligence in power system fault analysis and location[J]. Proceedings of the CSEE, 2020, 40(17): 5506.
- [10] 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.
- [11] BOCHKOVSKIY A, WANG C, LIAO H. YOLOv4: optimal speed and accuracy of object detection[J/OL]. arXiv, 2020; 1 – 17(2020-04-23)[2025-12-23]. <https://arxiv.org/abs/2004.10934>.
- [12] 顾超越, 李喆, 史晋涛, 等. 基于改进 Faster-RCNN 的无人机巡检架空线路销钉缺陷检测[J]. 高电压技术, 2020, 46(9): 3089.
GU Chaoyue, LI Zhe, SHI Jintao, et al. Detection for pin defects of overhead lines by UAV patrol image based on improved Faster-RCNN[J]. High Voltage Engineering, 2020, 46(9): 3089.
- [13] ZHAO W, XU M, CHENG X, et al. An insulator in transmission lines recognition and fault detection model based on improved Faster RCNN[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1.
- [14] 王凌云, 万旭东, 刘兰兰, 等. 基于改进 YOLOX 的输电线路典型部件及缺陷轻量检测方法[J]. 电机与控制学报, 2025, 29(9): 106.
WANG Lingyun, WAN Xudong, LIU Lanlan, et al. Light weight detection method for typical components and defects of transmission lines based on improved YOLOX[J]. Electric Machines and Control, 2025, 29(9): 106.
- [15] 王媛彬, 李媛媛, 段誉, 等. 基于轻量骨干网络和注意力结构的变电设备红外图像识别[J]. 电网技术, 2023, 47(10): 4358.
WANG Yuanbin, LI Yuanyuan, DUAN Yu, et al. Infrared image recognition of substation equipment based on lightweight backbone network and attention mechanism[J]. Power System Technology, 2023, 47(10): 4358.
- [16] 刘闽, 李喆, 李曜丞, 等. 基于重参数化 YOLOv5 的输电线路缺陷边缘智能检测方法[J]. 高电压技术, 2024, 50(5): 1954.
LIU Min, LI Zhe, LI Yaocheng, et al. Transmission line defect edge intelligent inspection method based on re-parameterized YOLOv5[J]. High Voltage Engineering, 2024, 50(5): 1954.
- [17] 郝帅, 杨磊, 马旭, 等. 基于注意力机制与跨尺度特征融合的 YOLOv5 输电线路故障检测[J]. 中国电机工程学报, 2023, 43(6): 2319.
HAO Shuai, YANG Lei, MA Xu, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion[J]. Proceedings of the CSEE, 2023, 43(6): 2319.
- [18] 周华平, 吴劲, 李敬兆, 等. 结合并行池化与自蒸馏的 YOLO 红外目标检测算法[J]. 红外技术, 2024, 46(8): 883.
ZHOU Huaping, WU Jin, LI Jingzhao, et al. YOLO infrared tar-

get detection algorithm combining parallel pooling and self-distillation[J]. Infrared Technology, 2024, 46(8): 883.

[19] 颜宏文, 万俊杰, 潘志敏, 等. 基于改进 YOLOv5-LITE 轻量级的配电组件缺陷识别[J]. 高电压技术, 2024, 50(5): 1855.

YAN Hongwen, WAN Junjie, PAN Zhimin, et al. Defect identification of distribution components based on improved YOLOv5-LITE lightweight[J]. High Voltage Engineering, 2024, 50(5): 1855.

[20] CAO Y, XU J, LIN S, et al. GCNet: non-local networks meet squeeze-excitation networks and beyond[C]//Proceedings of the 2019 International Conference on Computer Vision Workshops (ICCVW), October 27 – 28, 2019, Seoul, Korea. 2019: 1971 – 1980.

[21] YANG B, BENDER G, LE Q, et al. CondConv: Conditionally parameterized convolutions for efficient inference[C]//Advances in Neural Information Processing Systems 32 (NeurIPS 2019), December 8 – 14, 2019, Vancouver, Canada. 2019: 1 – 12.

[22] CHEN Y, DAI X, LIU M, et al. Dynamic convolution: attention over convolution kernels[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2020), June 14 – 19, 2020, Seattle, USA. 2020: 11027 – 11036.

[23] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[C]//Proceedings of the International Conference on Learning Representations (ICLR 2022), April 25 – 29, 2022, Virtual Event. 2022: 1 – 20.

[24] 曾宏宇, 杨冰, 许涛, 等. 基于红外图像目标检测与温度特征提取的变压器套管发热缺陷识别[J]. 广东电力, 2023, 36(3): 99.

ZENG Hongyu, YANG Bing, XU Tao, et al. Heating defect recognition of transformer bushing based on infrared image target detection and temperature feature extraction[J]. Guangdong Electric Power, 2023, 36(3): 99.

[25] 肖懿, 罗丹, 蒋沁知, 等. 基于温度概率密度的变电站高压设备故障热红外图像识别方法[J]. 高电压技术, 2022, 48(1): 307.

XIAO Yi, LUO Dan, JIANG Qinzhi, et al. Thermal infrared image recognition method for high voltage equipment failure in substation based on temperature probability density[J]. High Voltage Engineering, 2022, 48(1): 307.

(编辑:邱赫男)