

文章编号:1001-5078(2024)04-0584-09

· 红外技术及应用 ·

基于改进 Faster R-CNN 的光伏组件红外热斑检测算法

季瑞瑞¹, 梅远¹, 杨思凡¹, 骆丰凯¹, 储小帅¹, 张龙², 王朵², 李珂明²

(1. 西安理工大学 自动化与信息工程学院, 陕西 西安 710048; 2. 国网西安供电公司, 陕西 西安 710032)

摘要: 光伏故障检测对光伏电站智能运维具有重要意义。针对光伏组件红外图像中热斑目标小、难检测的问题, 研究了基于改进 Faster R-CNN 的光伏组件红外热斑故障检测模型。将 Swin Transformer 作为 Faster R-CNN 模型中的特征提取模块, 捕获图像的全局信息, 建立特征之间的依赖关系, 提高模型的建模能力; 进一步利用 BiFPN 进行特征融合, 改善了热斑故障由于目标小和特征不明显容易被模型忽略掉的问题; 同时为了抑制光伏红外图像中背景和噪声的干扰, 加入轻量级注意力模块 CBAM, 使模型更加关注重要通道和关键区域, 提高对热斑故障检测精度。在自建光伏组件图像数据集上进行实验, 热斑故障检测精度高达 91.5%, 验证了本文模型对光伏组件热斑故障检测的有效性。

关键词: 光伏组件; 红外图像; 故障检测; Faster R-CNN; 特征融合

中图分类号: TN219; TP391 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2024.04.015

Infrared hot spot detection in photovoltaic modules based on improved Faster R-CNN

Ji Rui-rui¹, Mei Yuan¹, Yang Si-fan¹, Luo Feng-kai¹, Chu Xiao-shuai¹,
Zhang Long², Wang Duo², Li Ke-ming²

(1. School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. State Grid Xi'an Electric Power Supply Company, Xi'an 710032, China)

Abstract: Photovoltaic fault detection is of great significance to the intelligent operation and maintenance of photovoltaic power plants. To address the problem of small targets and difficult detection of hot spots in infrared images of photovoltaic modules, an infrared hot spot fault detection model for PV modules based on improved Faster R-CNN is studied. Swin Transformer is employed as the feature extraction module in the Faster R-CNN model to capture the global information from the images and establish dependencies between the features, thereby enhancing the modeling capability of the model. Furthermore, the BiFPN is utilized for feature fusion, improving the issue of thermal spot faults that are easily ignored by the model due to the small target and inconspicuous features. Additionally, to suppress interference from background and noise in photovoltaic infrared images, a lightweight attention module called CBAM is incorporated to enable the model to focus more on important channels and key regions, so as to improve the accuracy of thermal spot fault detection. Experimental evaluations are conducted on a self-built dataset of photovoltaic component images, resulting in an impressive detection accuracy of 91.5%, which validates the effectiveness of the proposed model for detecting thermal spot faults in photovoltaic components.

Keywords: photovoltaic module; infrared image; fault detection; Faster R-CNN; feature fusion

基金项目: 陕西省产业化项目 (No. 2020ZDLGY04-04); 国网陕西省电力有限公司科技项目 (No. 5226XA220002) 资助。

作者简介: 季瑞瑞 (1978-), 女, 博士, 副教授, 研究方向为深度学习、智能图像处理、红外目标检测。E-mail: jirui@xaut.edu.cn

收稿日期: 2023-07-14; **修订日期:** 2023-08-14

1 引言

光伏发电产业已经成为我国的新能源产业的支柱之一。光伏组件的老化失配、热斑、接地等故障都会严重缩短电站运行年限,甚至会引起电站发生火灾事故。在大型光伏电站运行维护中,人工巡检方式成本高,效率低,劳动强度大,并存在安全风险。为了保证电站高效发电,降低电站运维成本,开发设计光伏组件智能检测系统对整个光伏电站的运营和维护具有重要的意义^[1]。

当光伏组件出现裂纹、遮挡、阴影等情况时,光伏组件局部会升温,产生热斑,造成组件结构的损坏。目前常用的光伏组件热斑故障检测方法大致分为两大类,分别是基于光伏组件电气特性和基于红外图像的热斑故障检测方法。基于电气特性监控的热斑故障检测方法有基于 I-V 特征曲线^[2-4]进行热斑故障检测和通过负载功率建立模型^[5-6]来进行热斑故障检测,该类方法的实现原理简单,但增加了电站的成本,同时由于检测数据易受环境因素影响,模型检测精度并不高,定位故障能力差。

基于红外图像的热斑故障检测法是利用计算机视觉对红外图像进行处理,由于热斑所在区域与正常区域的温度不同,可以提取红外图像中光伏组件的温度特征,实现热斑故障的检测和定位。杨亚楠^[7]通过基于改进 K-means 算法实现光伏阵列特征和背景特征的分离,再利用支持向量机模型实现对热斑严重程度的分类。M. Alajmi^[8]等人基于斯特法定律利用光伏组件发射的红外辐射来分析物体的热能量分布情况,根据不同故障类型的温度分布图像不同进行故障分类。蒋琳^[9]等人利用 B 样条最小二乘拟合灰度直方图曲线来实现热斑的检测。陈文勤^[10]通过提取热斑红外温度特征并使用 SVM 实现对光伏热斑故障的检测。郭梦浩^[11]提出一种基于改进的 Faster R-CNN 热斑检测模型,通过调整 VGG16 结构和对 RPN 网络进行修改以提高热斑故障的检测精度。栾艳军^[12]提出一种利用改进 Canny 算法与航拍红外图像相结合的方法来进行光伏阵列热斑故障检测。李鑫林^[13]将生成对抗网络与图像重构相结合实现对热斑故障的检测。红外热成像的优势在于能够定位到热斑故障的具体位置^[14],且不需要额外安装大量传感器来获取光伏组件的电气参数,节约了电站成本。但由于光伏组件红外图

像特征单一,特征之间相似度高,使得常规的检测算法在训练时很难学习到红外图像中热斑和光伏组件特征,缺乏对整幅图像的全局认知,会导致热斑特征和背景杂质特征混淆,造成热斑和组件的漏检。

为此,提出基于 Swin Transformer^[15-16]的改进 Faster R-CNN 热斑故障检测模型,利用特征提取网络中的 Transformer 模块捕获图像的全局信息^[17],建立特征之间的依赖关系,提高模型的建模能力;为了改善热斑故障由于目标小^[18]和特征不明显容易被模型忽略掉的问题,加入了特征融合网络和注意力机制。

2 基于改进 Faster R-CNN 模型的热斑故障检测

2.1 整体框架

提出的网络整体框架如图 1 所示,本网络由特征提取、特征融合、候选框生成和分类与回归四个模块构成。特征提取模块使用 Swin Transformer 网络实现对光伏组件红外图像的全局感知与特征之间关系的捕捉;特征融合模块使用 BiFPN^[19]网络对不同层的特征图进行融合来减少小目标故障的特征信息在下采样过程中的丢失,同时通过 CBAM 注意力机制^[20]来抑制红外图像中背景和噪声的干扰,使模型关注重要通道和关键区域;候选框生成模块使用 RPN 网络生成包含检测光伏组件和故障的候选框,分类与回归模块通过两个全连接层分别预测光伏组件故障的类别和坐标,从而实现对光伏组件红外图像的热斑故障检测。




图 1 网络整体框架

Fig. 1 Overall framework

2.2 特征提取模块

卷积参数共享的特性使得提取出来的光伏组件红外图像的特征单一,不能根据输入图像灵活地调整卷积核参数,同时卷积核的大小限制了卷积操作捕获长距离关系的能力。本文使用 Swin Transformer 作为 Faster R-CNN 的特征提取网络,整体模型结构如图 2 所示,包含三个主要模块:Token 嵌入模块、Patch Merging 模块以及 Transformer 模块。Swin Transformer 采用窗口策略,既保留了 Transformer 并

发处理、超大感受野、通用性强等优点,又通过逐层堆叠的方式加深拓宽网络深度方式吸收了卷积神经网络的层次性、平移不变性等优点,使得模型能够提取到更加丰富的特征。




图 2 Swin Transformer 结构图

Fig. 2 Architecture diagram of Swin Transformer

2.2.1 Token 嵌入模块

Token 是模型的最小输入单位,本文将原始的输入图像切分为像素大小一致的区域,将每个区域视为一个 Token。Token 嵌入模块操作流程如图 3 所示,该模块首先利用步距为 4 大小为 4 × 4 通道数为 96 的卷积核,将输入大小为 224 × 224 × 3 的图像 shape 为 56 × 56 × 48,相当于将输入光伏红外图像中每 4 × 4 大小的像素区域作为一个 Token,一共划分成 56 个 Token;接着通过步长为 1 大小为 1 × 1 通道数为 96 的卷积核将每个图像块线性映射到一维向量中。由于每个图像块都包含位置信息,为了使模型学习到不同位置之间的相关性,对线性变化后的 Token 加上位置编码(Position Embedding)。




图 3 Token 模块示意图

Fig. 3 Schematic diagram of Token module

2.2.2 Patch Merging 模块

图像编码后,为了得到特征的层次化结构,对运算量进行压缩,需采用池化层进行下采样。平均池化和最大值池化在下采样的过程中会均会引起特征图信息的丢失,尤其是光伏组件热斑故障的特征信息丢失,从而降低模型故障检测精度。本文使用 Merging 层进行下采样,在不丢失特征的情况下使特征图通道数变为原来的两倍。首先将编码后得到大小为 N × N 的特征图划分成 4 个不重叠的 N/2 × N/2 的特征图;接着把特征图重新进行组合得到 4

个新的特征图;然后将特征图按深度方向进行拼接,使特征图深度由原来的 C 变为 4C;最后经过层归一化和线性变化后将特征图的深度变为 2C,实现对特征图的下采样。特征图合并过程如图 4 所示。




图 4 Patch Merging 模块示意图

Fig. 4 Schematic diagram of Patch Merging

2.2.3 Transformer 模块

Transformer 模块采用与卷积网络相似的残差连接,将窗口多头自注意力(Windows Multi-Head Self-Attention, W-MSA)、多层感知机(Multi-Layer Perceptron, MLP)、移位窗口多头自注意力(Shifted Windows Multi-Head Self-Attention, SW-MSA)三个部分依次组合起来,并在每个部分前加入层归一化(Layer Normalization, LN),使输入分布稳定,降低内部协变量漂移的影响。模块结构如图 5 所示。




图 5 Transformer 模块结构图

Fig. 5 Architecture diagram of Transformer module

(1) 窗口注意力机制

窗口注意力通过计算查询(Query)与键(Key)、值(Value)之间相关性实现特征的动态聚合。在光伏组件红外图像中,左上角区域和右下角区域距离较远,因此两个区域特征之间相关性程度低,采用全局注意力机制,会使计算量增大,提取到的特征反而会变差。因此本文将提取到光伏组件红外图像特征图划分成多个窗口,在每个窗口内部进行自注意力计算,使模型在局部获得更强的感知能力。本文使用的 Swin-B 模型窗口大小 7 × 7,在 Stage1 中多头自注意力的个数为 4,计算过程如图 6 所示。将输入大小为 96 × 56 × 56 大小的特征图经过 1 × 1 卷积后映射为 288 × 56 × 56 的特征图,对特征图按通道数进行划分,得到 3 个 96 × 56 × 56 的特征图,即为 Query、Key 和 Value。最后将计算结果加权求和后,通过 Rearrange 操作将特征图调整为与输入尺寸一致的大小。




图6 基于窗口的多头自注意力

Fig.6 Window-based multi-head self-attention

(2) 移动窗口注意力机制

通过引入窗口可以极大降低自注意力的计算复杂度,但是自注意力的计算只会在窗口内部进行计算,造成了窗口与窗口之间无法进行信息传递的问题。Swin Transformer 在每次 W-MSA 之后加入 SW-MSA 模块,来进行窗口的移动并再次计算自注意力机制,实现不同窗口间信息的交互。窗口自注意力机制原理如图 7 所示。图 7(a)为第 L 层的 W-MSA,将原特征图划分成了 4 个 4 × 4 大小的窗口,图 7(b)为第 L + 1 层的 SW-MSA,通过比较两幅图可以看出使用 SW-MSA 后窗口发生了偏移,形成了新的 9 个大小不一的窗口。在新生成的 9 个窗口内进行自注意力的计算实现了图 7(a)中 4 个独立窗口的信息交流,使的所有窗口产生交互。




图7 移动窗口注意力示意图

Fig.7 Schematic diagram of shifted windows multi-head self-attention

移动窗口注意力计算如式(1)、(2)、(3)、(4)所示:

$$\hat{z}^l = WMSA(LN(z^{l-1})) + z^{l-1} \quad (1)$$

$$z^l = SE(LN(\hat{z}^l)) + \hat{z}^l \quad (2)$$

$$\hat{z}^{l+1} = SWMSA(LN(z^l)) + z^l \quad (3)$$

$$z^{l+1} = SE(LN(\hat{z}^{l+1})) + \hat{z}^{l+1} \quad (4)$$

其中, \hat{z}^l 是第 l - 1 层的 SW - MSA 通过 MLP 后得到的特征, z^l 是第 l 层的 W - MSA 通过 MLP 后得

到的特征, LN 的作用是对输入数据进行归一化操作保证数据特征分布的稳定性, MLP 的作用是对特征图进行非线性映射,增强模块的非线性表达能力。

2.3 特征融合模块

2.3.1 多尺度热斑特征融合方法研究

在 Faster R-CNN 模型中, RoI Pooling 只在最后一层特征图上执行来生成候选框区域。然而这种方法会忽略光伏热斑这种小目标的一些重要特征,因为在深层的特征图中感受野大、语义信息丰富,能更好的进行分类,但是位置信息模糊,小尺度热斑特征在深层特征中很难保留下来,所以导致模型很难检测出热斑故障。由于浅层的特征图感受野小,但位置信息更精准,有更多的细粒度信息和上下文信息,所以在目标检测任务中,常常融合多个特征图来提升算法对小目标检测的性能。本文的多尺度融合模块整体采用 BiFPN 结构,其结构如图 8 所示。图 8 中 $F_3 \sim F_7$ 为输入特征图, $N_3 \sim N_7$ 为融合后特征图。




图8 BiFPN 结构图

Fig.8 Architecture diagram of BiFPN

BiFPN 采用快速归一化融合方法对不同层特征进行加权融合,如下式所示:

$$O = \sum_i \frac{w_i \cdot I_i}{\varepsilon + \sum_j w_j} \quad (5)$$

BiFPN 结构第 6 层级的特征融合如式(6)和式(7)所示:

$$P_6 = \text{Conv}\left(\frac{w_1 \cdot F_6 + w_2 \cdot \text{resize}(F_7)}{w_1 + w_2 + \varepsilon}\right) \quad (6)$$

$$N_6 = \text{Conv}\left(\frac{w'_1 \cdot F_6 + w'_2 \cdot P_6 + w'_3 \cdot \text{resize}(N_5)}{w'_1 + w'_2 + w'_3 + \varepsilon}\right) \quad (7)$$

其中, F_6 为第 6 层的输入特征; P_6 为自上而下路径第 6 层的中间特征; N_6 为第 6 层融合后的特征; w_i 是学习到的参数,用于区分特征融合过程中不同特征的重要程度; ε 是避免数值不稳定,resize 操作通常是下采样或上采样操作。

2.3.2 基于注意力机制的热斑故障检测

CBAM 是一个简单高效、即插即用的轻量级注意力模块,在光伏组件红外数据集上存在热斑目标尺度小、组件排列密集、背景和噪声干扰等现象,加入注意力机制可以保留热斑故障更多的关键特征、抑制无关信息的干扰、提高热斑故障检测精度,并且其空间注意力机制有助于目标的定位。添加 CBAM 模块后的网络结构如图 9 所示,在进行多尺度特征融合前加入 CBAM 模块,先对特征图进行特征加强,来提升网络对小目标的关注度,然后再进行特征融合,这样使融合后的特征图包含更多关键特征,从而提高小目标的定位精度。

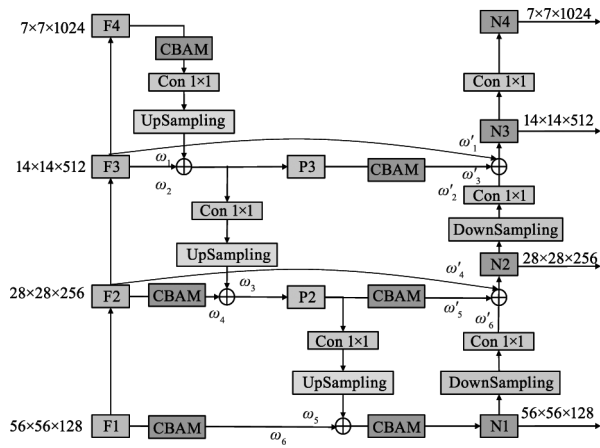


图 9 BiFPN-CBAM 结构图

Fig. 9 Architecture diagram of BiFPN-CBAM

2.4 候选框生成模块

由于每张拍摄的光伏组件红外图像中的光伏组件数量众多,为了保证检测率,本文使用两阶段目标检测方法,即先通过 RPN 网络生成一系列可能包含光伏组件的候选框,然后再做出进一步的判断,得出最终的检测结果。

RPN 损失函数由分类损失和边界框回归损失两部分构成,如式(8)所示。

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (8)$$

其中, p_i 表示第 i 个 anchor 预测为真实标签的概率; p_i^* 当为正样本时为 1, 当为负样本时为 0; t_i 表示预测第 i 个 anchor 的边界回归参数; t_i^* 表示第 i 个 anchor 对于真实标注框的回归参数; N_{cls} 表示一个 mini-batch 中所有样本数量; N_{reg} 表示 anchor 位置的

个数。通过候选框生成模块后,保留包含目标的候选框,可以减少分类与回归模块中的计算量。

2.5 分类与回归模块

检测网络的作用是对目标进行更详细的分类,并且进一步调整预测框的坐标。与 RPN 损失函数类似检测网络损失同样由分类损失和回归损失组成,其公式如式(9)、(10)、(11)所示:

$$L(p, u, t^u, v) = L_{\text{cls}}(p, u) + \lambda [u \geq 1] L_{\text{loc}}(t^u, v) \quad (9)$$

$$L_{\text{cls}}(p, u) = -\log p_u \quad (10)$$

$$L_{\text{loc}}(t^u, v) = \sum_{i \in \{x, y, w, h\}} \text{smooth}_{L_1}(t_i^u - v_i) \quad (11)$$

其中, p 是分类器的 softmax 概率分布 $p = (p_0 \cdots p_k)$; u 对应目标真实类别标签; v 表示候选框坐标; t^u 表示 ground truth 坐标, λ 平衡分类损失和回归损失之间的权重。通过分类与回归模块,可以实现故障分类和边界框的预测。

3 实验过程与结果分析

3.1 光伏数据集建立

本文使用 LabelImg 标注软件对拍摄的光伏数据集进行标注,最终得到 240 张标注完整的光伏组件红外图像,标注范式如图 10 所示。




图 10 光伏数据集标注范式

Fig. 10 Paradigm of PV dataset annotation




图 11 数据增强

Fig. 11 Data enhancement

为了使模型具有更好的泛化能力,对光伏数据集进行数据增强,具体操作为:随机旋转、缩放、翻转和平移等操作。增强后的数据集数量为 800 张,以光伏数据集中的一张图片为例,增强过程示意图如图 11 所示。

3.2 实验设置

实验所使用的硬件平台为 Intel (R) Xeon (R) Gold6330 14 核 CPU,开发环境为 Ubuntu18.04 系统

下的 Python3.8 语言, NVIDIA RTX3090 显卡, 24 G 显存, 开发工具为 PyCharm, 实验模型基于 PyTorch1.9.0 深度学习框架进行搭建, 搭载 Cuda11.1 高性能 GPU 计算。

训练模型时, 先将输入的图像缩放成统一尺寸大小, 进行标准化处理, 并采用随机翻转策略, 当概率超过 0.5 时对输入图像进行水平反转来提高模型的泛化能力。整体实验过程采用 SGD 作为训练优化器, 将总的 epoch 设置为 20, 学习率初始化为 0.005, 每隔 5 个 epoch 将学习率降低为之前的 0.33 倍。加入动量可以加快收敛速度, 权重衰减系数作用是调节模型复杂度对损失函数性能的影响, 为防止过拟合, 动量设为 0.9, 权重衰减系数设为 0.0005。采用目标检测常用的评价指标精准率 AP 来评价模型, 如式:

$$AP = \frac{TP}{TP + FP} \times 100 \% \quad (12)$$

其中, TP 表示真正例, 即正样本被判定为正样本的样本数量; FP 表示假正例, 即负样本被判定为正样本的样本数量。

3.3 实验与结果分析

本文设置四组实验来验证模型的性能, 实验一在 Faster R-CNN 模型基础上, 验证采用不同的骨干网络对检测精度的影响; 实验二将本模型与其他常用检测模型进行比较; 实验三为消融实验。

3.3.1 改进特征提取网络结果与分析

为了验证 Swin Transformer 特征提取能力, 本文通过使用不同的特征提取网络替换 Faster R-CNN 骨干网络来进行对比实验, 其结果如表 1 所示。

表 1 不同特征提取网络检测结果对比
Tab. 1 Comparison of detection results of different feature extraction networks

Backbone	Spot/%	Normal/%	mAP/%	FLOPs
ResNet50 ^[21]	69.4	91.8	80.6	7.95 G
VGG16 ^[22]	67.7	88.2	78.0	12.52 G
GoogLeNet ^[23]	68.5	90.2	79.4	5.53 G
ResNext50 ^[24]	70.2	92.4	81.3	10.27 G
Swin-B	77.8	93.6	85.2	6.83G

从表 1 中可以看出使用 Swin-B 作为 Faster R-CNN 骨干网络提取特征相比于 Faster R-CNN 原始

骨干网络 VGG16 在热斑故障检测精度提升了 10.1%, 光伏组件检测精度提升了 5.4%, mAP 提升了 7.2%, 各方面检测精度都优于 VGG16。Swin-B 与其他卷积网络相比, 检测小目标热斑故障的准确率最高, 优于卷积神经网络提取目标特征能力, 更有利于热斑的定位。

如图 12 所示, 通过不同特征提取网络的准确率对比图可以看出 Swin-B 斜率变速度更快, 上升速度明显, 更快达到收敛。图 13 为不同特征网络的 Faster R-CNN 模型在热斑故障上的 P-R 曲线, VGG 网络 P-R 曲线震荡最剧烈, 对热斑故障检测能力最差, 存在大量的漏检和误检情况。与其余 5 个网络相比 Swin-B 网络 P-R 曲线震荡相对较缓, 与坐标轴围的面积最大, 对热斑故障检测效果最好。




图 12 不同 backbone 准确率对比

Fig. 12 Accuracy comparison of different backbones




图 13 不同 backbone 热斑故障 P-R 曲线

Fig. 13 P-R curves for hot spot faults with different backbones

3.3.2 使用不同检测模型结果与分析

为验证改进模型的性能, 现将改进模型与 SSD、Faster R-CNN 和 YOLOv4 模型进行横向对比, 各模型的训练准确率如图 15 所示。不同模型的运算时间和识别准确率对比如表 2 所示。

由图 14 和表 2 可以看出,改进后模型拥有最高的准确率,尤其在热斑故障检测精度出众,充分说明改进模型的有效性。本模型在检测性能远远高于原始 Faster R-CNN 模型,并且只增加了少量的计算时间。虽然 SSD 和 YOLOv4 都为单阶段模型,拥有更快的检测速度,但是检测精度并不适合处理光伏组件红外图像故障检测任务。本模型在保证高准确率的同时也保证了快速性,具有良好的实用性。

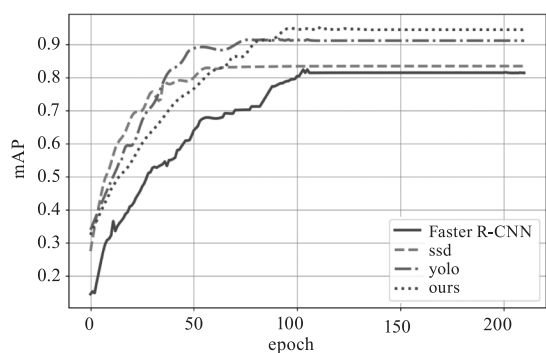


图 14 不同模型 mAP 曲线对比

Fig. 14 Comparison of mAP curves with different models

表 2 不同模型实验对比

Tab. 2 Comparison of different model experiments

模型	Spot/%	Normal/%	mAP/%	运算时间/s
Faster R-CNN	69.4	91.8	80.6	0.155
SSD	74.3	92.5	83.4	0.094
YOLOv4	83.8	96.3	90.1	0.068
Ours	91.5	97.2	94.4	0.182

表 3 识别结果统计

Tab. 3 Recognition result statistics

模型	TP	FP	FN	TN
Faster R-CNN	35	6	8	4248
SSD	37	4	6	4250
YOLOv4	40	3	3	4251
Ours	42	0	1	4254

为了进一步衡量改进模型的性能与识别精度,现通过对各模型热斑故障的查准率、查全率和 F1-score 三种评价指标进行对比分析。在 120 张测试集光伏红外图像上各模型统计结果如表 3 所示,热斑故障设置为检测目标时,TP 表示为正确检测出来的热斑故障个数, FN 表示未被检测出来的热斑故障个数, FP 表示将正常组件检测为热斑故障个数, TN 表示正常组件被正确检测的个数。

得到表 3 统计的数据后,可以得到各模型查准率、查全率和 F1-score,结果如表 4 所示。

表 4 各模型热斑故障检测结果对比

Tab. 4 Comparison of hot spot detection results with different models

模型	精确率	召回率	F1-score	漏检率
Faster R-CNN	0.854	0.814	0.834	0.186
SSD ^[25]	0.902	0.860	0.880	0.140
YOLOv4 ^[26]	0.930	0.930	0.930	0.070
Ours	1.0	0.977	0.988	0.023

由表 4 可以看到,改进后模型的热斑故障检测性能评价指标都优于其他模型,在精确率上比 Faster R-CNN、SSD、YOLOv4 分别高了 14.6%、9.8%、7.0%,在召回率上分别高了 16.3%、11.7%、4.7%,并且拥有最高的 F1-score 达到 0.988 和最低的漏检率 2.3%。由以上分析可知,本文提出的改进模型能够提高对热斑特征提取能力和抑制背景的干扰,解决热斑故障识别困难的问题,并且与其他模型相比更具有优势。

3.3.3 消融实验

为验证引入模块的有效性,本文在光伏红外图像测试集上的消融实验如表 5 所示,由表第四行可以看出在 Faster R-Swin 单独加入 CBAM 模块对模型整体检测性能提升不大, AP_{spot} 和 AP_{normal} 分别提升了 0.6% 和 0.7%,这是因为特征图经过多次下采样操作到最后输出层时丢失了很多小目标的信息,使得 CBAM 模块很难发挥作用。可以看出单独加入 BiFPN 网络后,模型的召回率、精确率、 AP_{normal} 和 AP_{normal} 相对于原模型分别提升了 4.3%、5.2%、11.8%、2.5%,这是因为通过双向特征融合可以减少小目标信息的丢失,并且在不同尺度的特征图上设置不同面积大小的 anchor 使得模型能检测到的小目标数量增多,性能指标也随之提升。将 CBAM 模块和 BiFPN 组合后模型检测效果变得更好,这是因为在进行不同层特征融合之前 CBAM 对特征图的关键区域和通道特征进行了加强,使得融合后的特征图能更好的保留热斑特征信息。将训练完成后的模型在光伏测试集上进行检测,检测结果如图 15 所示,可以看出本文提出的方法在热斑故障检测方面取得了良好的效果。

表 5 消融实验结果

Fig. 5 Results of ablation experiment

Swin-B	BiFPN	CBAM	P/%	R/%	AP _{spot} /%	AP _{normal} /%
×	×	×	85.4	81.4	69.4	91.8
√	×	×	91.1	87.5	77.8	93.6
×	√	×	93.7	89.2	81.3	94.2
×	×	√	88.3	84.7	72.6	92.5
√	√	×	95.4	92.7	89.6	96.1
√	×	√	90.5	86.3	78.4	94.3
×	√	√	94.5	91.4	87.9	95.4
√	√	√	100	97.7	91.5	97.2




图 15 光伏组件红外图像检测结果

Fig. 15 Results of photovoltaic module infrared image detection

4 结 语

大多数基于深度学习的目标检测方法难以对光伏组件中热斑这种小目标故障进行检测,本文提出改进的 Faster R-CNN 的光伏组件故障检测模型,将 Swin Transformer 代替传统卷积神经网络作为特征提取网络,使网络可以捕捉光伏红外图像全局信息并建立特征点之间的依赖关系,解决了红外图像中特征提取困难的问题;在模型中加入 BiFPN 网络将低层特征中细节特征和高层特征中语义特征进行双向融合,提升特征图对热斑特征表达能力;在模型中加入 CBAM 注意力机制,抑制背景和噪声的干扰,使模型关注重要通道和关键区域,增强热斑位置信

息。在自建光伏数据集上进行实验,实验结果表明本文模型可以实现热斑故障的高精度检测。在未来工作中将结合自然光光伏图像来实现更多种类和更精确的光伏组件故障分类。

参考文献:

- [1] Zheng Jianwen. Research and application of fault diagnosis method for photovoltaic power generation equipment based on artificial intelligence[J]. Power System Equipment, 2021, (24): 109-110. (in Chinese)
郑建文. 基于人工智能的光伏发电设备故障诊断方法研究与应用[J]. 电力系统装备, 2021, (24): 109-110.
- [2] Wu Chunhua, Zhou Diqing, Li Zhihua, et al. Diagnosis of photovoltaic module Hot spots and fuzzy optimization control method[J]. Proceedings of the Chinese Society of Electrical Engineering, 2013, 33(36): 50-61, 9. (in Chinese)
吴春华, 周笛青, 李智华, 等. 光伏组件热斑诊断及模糊优化控制方法[J]. 中国电机工程学报, 2013, 33(36): 50-61, 9.
- [3] Hossam B, Itako K. Real time hotspot detection using scan-method adopted with P&O MPPT for PV generation system[C]//Annual Southern Power Electronics Conference. Auckland, New Zealand; IEEE Press, 2016: 1-5.
- [4] Jiang Dongxiao. Research on fault diagnosis of photovoltaic arrays based on data mining[D]. Beijing: North China Electric Power University, 2016. (in Chinese)
姜栋潇. 基于数据挖掘的光伏阵列故障诊断研究[D]. 北京: 华北电力大学, 2016.
- [5] Bi Rui, Ding Ming, Xu Zhicheng, et al. Fault diagnosis method for photovoltaic arrays based on fuzzy C-means clustering[J]. Acta Energetica Solaris Sinica, 2016, 37(3): 730-736. (in Chinese)
毕锐, 丁明, 徐志成, 等. 基于模糊 C 均值聚类的光伏阵列故障诊断方法[J]. 太阳能学报, 2016, 37(3): 730-736.
- [6] Wang Y, Itako K, Kudoh T, et al. Voltage-based hot-spot

- detection method for PV string using projector [C] // International Conference on Power and Renewable Energy, Shanghai, China: IEEE Press, 2016: 570 – 574.
- [7] Yang Yanan. Research and implementation of solar photovoltaic array identification and hot spot detection technology [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2018. (in Chinese)
杨亚楠. 太阳能光伏阵列识别及热斑检测技术的研究与实现 [D]. 南京: 南京邮电大学, 2018.
- [8] M Alajmi, K Awedat, M S. Aldeen, et al. IR thermal image analysis: an efficient algorithm for accurate hot-spot fault detection and localization in solar photovoltaic systems [J]. IEEE Transactions on Industrial Electronics, 2019, 63 (5): 3159 – 3169.
- [9] Jiang Lin, Su Jianhui, Shi Yong, et al. Hot spot detection method for photovoltaic arrays based on infrared thermal image processing [J]. Acta Energetica Solaris Sinica, 2020, 41 (8): 180 – 184. (in Chinese)
蒋琳, 苏建徽, 施永, 等. 基于红外热图像处理的光伏阵列热斑检测方法 [J]. 太阳能学报, 2020, 41 (8): 180 – 184.
- [10] Chen Wenqin. Research and implementation of a photovoltaic module hot spot detection system based on infrared image recognition [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020. (in Chinese)
陈文勤. 一种基于红外图像识别的光伏组件热斑检测系统的研究与实现 [D]. 南京: 南京邮电大学, 2020.
- [11] Guo Menghao. Research on photovoltaic panel cleaning and hot spot detection system [D]. Hangzhou: China University of Metrology, 2020. (in Chinese)
郭梦浩. 光伏板清洁及热斑检测系统研究 [D]. 杭州: 中国计量大学, 2020.
- [12] Luan Yanjun. Intelligent fault recognition of photovoltaic module aerial infrared images [D]. Baoding: Hebei University, 2021. (in Chinese)
栾艳军. 光伏组件航拍红外图像的故障智能识别 [D]. 保定: 河北大学, 2021.
- [13] Li Xinlin. Research on hot spot detection of photovoltaic panels based on generative adversarial networks [D]. Jilin: Northeast Electric Power University, 2022. (in Chinese)
李鑫林. 基于生成式对抗网络的光伏板热斑检测研究 [D]. 吉林: 东北电力大学, 2022.
- [14] Gu Yan, Li Zhen, Yang Feng, et al. Complex background infrared vehicle detection algorithm based on improved Faster R-CNN [J]. Laser & Infrared, 2022, 52 (4): 614 – 619. (in Chinese)
顾燕, 李臻, 杨锋, 等. 基于改进 Faster R CNN 的复杂背景红外车辆检测算法 [J]. 激光与红外, 2022, 52 (4): 614 – 619.
- [15] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems, Long Beach: IEEE Press, 2017: 5998 – 6008.
- [16] Ze Liu, Yutong Lin, Yue Cao, et al. Swin transformer: hierarchical vision transformer using shifted windows [C] // International Conference on Computer Vision, Montreal, QC, Canada: IEEE Press, 2021: 9992 – 10002.
- [17] Kang Zixiang, Wang Shengzhe, Cui Yuyong, et al. Voxelized LiDAR point cloud object detection algorithm based on transformer [J]. Laser & Infrared, 2023, 53 (2): 202 – 207. (in Chinese)
康自祥, 王升哲, 崔雨勇, 等. 基于 Transformer 的体素化激光点云目标检测算法 [J]. 激光与红外, 2023, 53 (2): 202 – 207.
- [18] Wang Henghui, Cao Dong, Zhao Yang, et al. A review of deep learning-based infrared dim target detection algorithms [J]. Laser & Infrared, 2022, 52 (9): 1274 – 1279. (in Chinese)
王恒慧, 曹东, 赵杨, 等. 基于深度学习的红外弱小目标检测算法研究综述 [J]. 激光与红外, 2022, 52 (9): 1274 – 1279.
- [19] Tan M, Pang R, Le QV. Efficient det: scalable and efficient object detection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781 – 10790.
- [20] Woo S, Park J, Lee J Y, et al. Cbam: convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [21] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA: IEEE Press, 2016: 770 – 778.
- [22] K Simonyan, A Zisserman. Very deep convolutional net – works for large-scale image recognition [C] // International Conference on Learning Representations (ICLR), 2015.
- [23] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA: IEEE Press, 2015: 1 – 9.
- [24] Saining Xie, Ross Girshick, Piotr Dollár, et al. Aggregated residual transformations for deep neural networks [C] // Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA: IEEE Press, 2017: 5987 – 5995.
- [25] Liu Wei, et al. SSD: single shot multibox detector [C] // Proc of European Conference on Computer Vision. Cham: Springer, 2016: 21 – 37.
- [26] Bochkovskiy A, Wang C Y, Liao H Y M. Yolov4: optimal speed and accuracy of object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020.