

DOI:10.19651/j.cnki.emt.2209896

# 基于深度学习的航拍光伏板红外图像热斑检测方法研究<sup>\*</sup>

管宽岐<sup>1</sup> 蔺雨桐<sup>1</sup> 赵雨薇<sup>1</sup> 秦列列<sup>1</sup> 张楠楠<sup>1</sup> 曹英丽<sup>1,2</sup>

(1. 沈阳农业大学信息与电气工程学院 沈阳 110161; 2. 沈阳农业大学辽宁省农业信息化工程技术中心 沈阳 110161)

**摘要:** 针对光伏电站光伏板热斑故障难以检测的问题,结合无人机巡检技术,提出一种基于深度卷积神经网络的光伏板热斑快速检测方法。首先设计了光伏板识别模型,将 Yolov4 主干特征提取网络替换成轻量级网络 MobileNetV2,并将 PANet 网络中标准  $3 \times 3$  卷积替换成深度可分离卷积,实现了将光伏板快速从红外图像中识别出来。为快速识别热斑并解决光伏板反光噪声问题,将 MobileNetV2 网络引入 DeeplabV3+ 模型中,改进由于下采样造成的目标缺失,并将交叉熵损失函数修改为 Dice 损失函数来进一步提高分割精度。试验结果表明,该方法能够准确识别光伏板热斑,光伏板识别准确率为 99.56%,检测速度为 22.1 帧/s。光伏板识别后的热斑分割准确度达到 95.99%,交并比 mIoU 达到 85.58,检测速度为 24.5 帧/s,该方法能够满足光伏板故障检测的需要。

**关键词:** 光伏电站;热斑检测;Yolov4;DeeplabV3+;Dice loss

中图分类号: TK514; TP391.4 文献标识码: A 国家标准学科分类代码: 510.40

## Photovoltaic hot spot detection of aerial infrared image based on deep learning

Guan Kuanqi<sup>1</sup> Lin Yutong<sup>1</sup> Zhao Yuwei<sup>1</sup> Qin Lielie<sup>1</sup> Zhang Nannan<sup>1</sup> Cao Yingli<sup>1,2</sup>

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110161, China;

2. Liaoning Engineering Research Center for Information Technology in Agriculture, Shenyang 110161, China)

**Abstract:** In view of the difficulty in detecting hot spots of photovoltaic panels in power stations in China, combined with UAV inspection technology, a fast detection method of hot spots of photovoltaic panels based on deep convolutional neural network was proposed. Firstly, a photovoltaic panel recognition model was designed. The Yolov4 backbone feature extraction network was replaced by the lightweight MobileNetV2 network, and the standard  $3 \times 3$  convolution in PANet was replaced by the deeply separable convolution, which could realize the rapid recognition of photovoltaic panels from infrared images. In order to quickly identify hot spots and solve the problem of reflective noise of photovoltaic panels, MobileNetV2 network is introduced into deeplabv3+ model, improve the target loss caused by sampling and the cross entropy loss function is modified to dice loss function to further improve the segmentation accuracy. The experimental results show that the method can accurately identify hot spots of photovoltaic panels, with an accuracy of 99.56% and a detection speed of 22.1 frames per second. The hot spot segmentation accuracy of photovoltaic panel recognition reaches 95.99%, MIoU reaches 85.58%, and the detection speed is 24.5 frames per second. This method can meet the needs of photovoltaic panel fault detection.

**Keywords:** distributed photovoltaic station; hot spot detection; Yolov4; DeeplabV3+; Dice Loss

## 0 引言

随着环境污染和能源危机日益加剧,可再生能源发电技术得到快速发展,以光伏为代表的可再生能源发电大量

接入配电网<sup>[1-3]</sup>。近年来光伏产业成本不断降低,产能迅速增长,2020 年光伏新增装机  $4.82 \times 10^7$  kW,同比增长 60.1%。但是,光伏电站光伏板极易受到灰尘、鸟粪、落叶的遮挡,如果不能及时进行清理,就会造成被遮挡电池片成

收稿日期:2022-05-10

\*基金项目:辽宁省重点研发计划项目(2020JH2/10200038)、国家自然科学基金(61903264)项目资助

为负载消耗能量,产生热斑故障<sup>[4-6]</sup>。热斑故障轻则使光伏板发电效率大大降低,重则损坏整片光伏板甚至存在火灾隐患。因此,进行光伏板热斑检测对光伏电站日常维护工作有着重要价值。

基于卷积神经网络的目标检测算法主要分为两阶段检测算法和一阶段检测算法,两阶段检测算法如 Faster-rcnn 虽然检测精度高,但由于其耗时长已几乎被一阶段检测算法(YOLO 等)取代,但对于解决精度和速度平衡问题仍具有研究意义。语义分割算法因其可以实现像素级分类被广泛应用于医学等领域,常见的算法有 Deeplabv3+, PSPnet 等,虽然这些算法在小目标上识别效果好,但在光伏板故障检测方面,检测速度和精度仍需提高。

目前,检验光伏板缺陷的方式主要围绕着图像处理、热成像、神经网络等<sup>[7]</sup>。蒋琳等<sup>[8]</sup>提出基于灰度直方图的 B 样条最小二乘拟合的处理方法来解决反光噪声的问题,但不适用于高航拍红外图片;王培珍<sup>[9]</sup>针对不同工作状态下太阳能电池工作温度不同这一特性,提出了通过对红外图像分析来检测热斑故障的方法,但是检测结果受到环境的影响较大;孙海蓉等<sup>[10-11]</sup>以深度卷积自编码网络模型用于小样本光伏热斑识别与定位,还在 Inception-v3 模型的基础上构建深度迁移学习模型,但是以上两种方法都只适用于小样本的热斑检测;王春<sup>[12]</sup>提出了生成对抗神经网络来进行热斑识别,但对存在不完整的光伏板组件的情况不适用;陈文勤<sup>[13]</sup>用光伏阵列区域局部灰度特征来进行光伏阵列分割,然后采用 SVM 进行热斑检测,但模型大训练时间长不适用于无人机实时检测。

鉴于以上问题及无人机实时检测的实际需求,本文通过对 Yolov4 主干特征提取网络进行替换,在保证精度的前提下实现对航拍红外图像光伏板的快速识别截取,解决红外图像地面背景影响热斑识别的问题。然后用替换特征提取网络的 Deeplabv3+ 语义分割算法对识别后的红外图像进行热斑检测,解决了阳光反射等造成的虚假热斑影响并完成热斑的快速识别。

## 1 光伏板航拍红外图像数据获取与预处理

### 1.1 光伏板红外图像获取

图像数据采集自辽宁省阜新市彰武县后新秋镇光伏电站,使用大疆经纬 M300 无人机搭载 XT2 云台相机采集 30 m 高度光伏板红外图像,拍摄时间为 2021 年 10 月 25 日,共采集到红外图像 2 188 张,筛选出含有光伏板的红外图像共 1 557 张用于网络训练和测试,试验采集原始图像如图 1 所示。

### 1.2 光伏板红外图像预处理

为了解决网络训练样本数不足及多样性不足的问题,需要利用数据增广来降低网络过拟合的风险<sup>[14-15]</sup>。本文首先使用的方法是对原图像进行随机旋转 0°~120°形成新图像,由于无人机拍摄航线设计问题,导致所拍摄光伏板图像

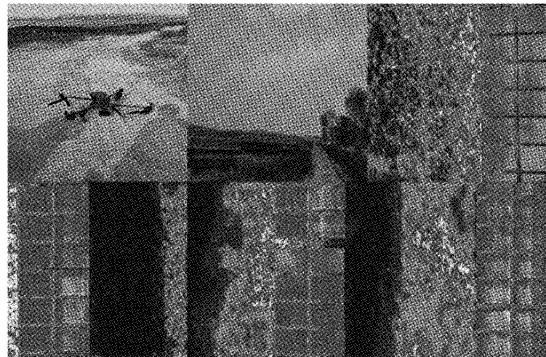


图 1 试验采集的原始图像

会出现一致性,通过随机角度旋转,可以解决样本多样性的  
问题。第 2 种方法是对图像进行压缩,模拟不同拍摄高度,  
不同像素的光伏板红外图片。第 3 种方法是改变对比度,  
模拟不同光照条件的光伏板图片。经过数据扩充后,光伏  
板红外图片达到 7 785 张,对其进行标注后进行光伏板识  
别模型的训练。根据热斑和光伏板的温度差异原理和人工  
筛选的方法对光伏板红外图片进行分析,由于光伏板反光  
和真实热斑形态不同,筛选出具有热斑的 1 610 张图片进  
行标注,用于热斑分割模型的训练。数据增广图像如图 2  
所示,光伏板反光虚假热斑和真实热斑图像如图 3 所示。

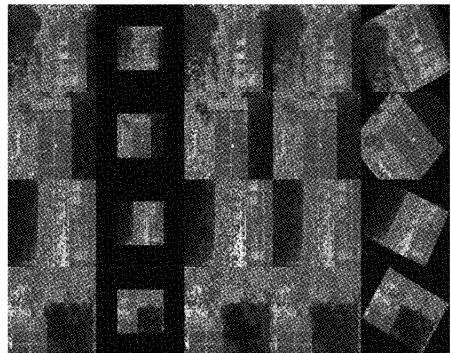


图 2 红外图像增广结果

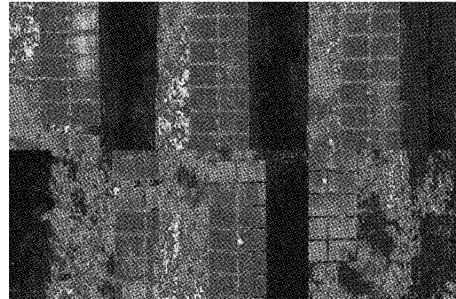


图 3 反光虚假热斑和真实热斑

## 2 航拍光伏板热斑检测方法

### 2.1 整体检测流程

本文首先基于改进的 Yolov4 算法设计了光伏板识别

模型,识别出光伏板并截取下来,然后利用改进的DeepLabV3+算法对截取的光伏板进行热斑分割,准确将热斑分割出来,流程如图 4 所示。

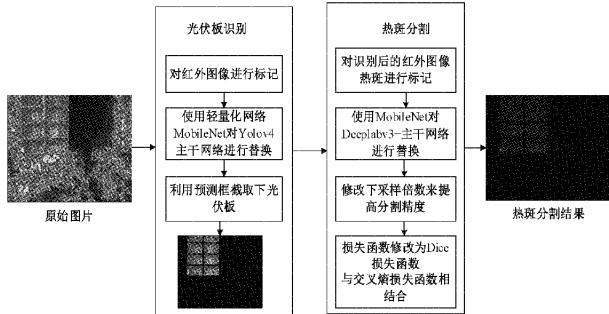


图 4 光伏板热斑检测流程

## 2.2 光伏板识别模型

### 1) Yolov4 算法

Yolov4 是在大量前人研究的基础之上,通过组合并创新算法,既提高了检测速度也确保了精确度。Yolov4 网络结构主要包括主干特征提取网络 CSPDarknet53、空间金字塔池化网络 SPP、加强特征提取网络 PANet 和预测网络 YOLO-Head。CSPDarknet53 用 Mish 激活函数激活,提升主干网络特征提取能力和网络稳定性,激活函数 Mish 和损失函数 CIoU-Loss 的表达式如式(1)~(4)所示。

$$\text{Mish} = x \times \tanh[\ln(1 + e^x)] \quad (1)$$

$$\text{Loss}_{\text{ciou}} = 1 - \text{IoU} + \frac{p^2(b, b^{gt})}{c^2} + \alpha v \quad (2)$$

$$a = \frac{v}{(1 - \text{IoU}) + v} \quad (3)$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (4)$$

式中: $b$  和  $b^{gt}$  为两个矩形框的中心点; $p$  为两个矩形框之间的欧式距离; $c$  为两个矩形框的闭包区域的对角线的距离; $v$  为长宽比的一致性; $\alpha$  为权重参数; $w, h$  为预测框的宽和高。

### 2) MobileNet 网络

MobileNet 网络所需计算资源少,适合移动设备,使用的是由深度卷积和逐点卷积构成的深度可分离卷积代替了标准卷积<sup>[16]</sup>。其中,深度卷积滤波器可以在不增加通道数量的基础上对输入的通道滤波,而逐点卷积滤波器可以增加通道的数量。这样就可以明显的减少计算量,可以在移动端布置,深度可分离卷积分解示意图如图 5 所示。

MobileNetV2 是在 MobileNetV1 基础上的升级,使用倒残差结构(inverted residual block)是其重要提高,整个 MobileNetV2 都由 inverted residual block 组成,其可以分为两个部分。如图 6 所示,左边是主干部分,相较于 MobileNetV1,首先进行  $1 \times 1$  卷积升维,获得更多的特征,然后进行  $3 \times 3$  深度可分离卷积,最后再用  $1 \times 1$  卷积降维。右边是残差边部分,输入和输出直接相接。

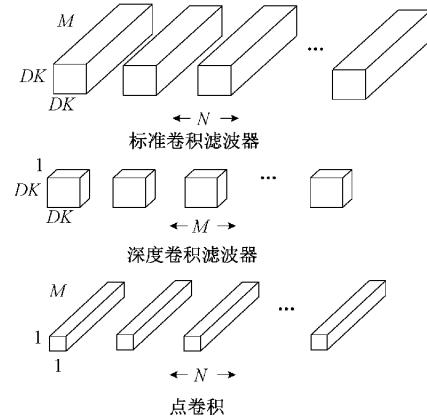


图 5 深度可分离卷积分解

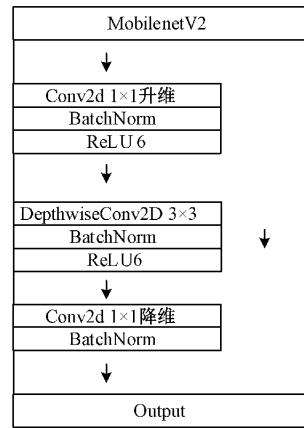


图 6 倒残差结构

### 3) Yolov4 算法的改进

本文提出的算法主要进行了两方面改进,一是分别用 MobileNetV1、MobileNetV2、MobileNetV3 网络对 Yolov4 主干特征提取网络 CSPDarknet53 进行替换,在保证精度的同时解决了 CSPDarknet53 网络特征提取时参数量和计算量较大问题,通过对比速度、检测精度、模型大小等,优选出在本文数据集中表现最优秀的 MobileNetV2 网络作为模型的特征提取网络。二是将加强特征提取网络 PANet 中标准  $3 \times 3$  卷积替换为计算参数量较小的深度可分离卷积,进一步减少计算参数量,改进算法网络结构如图 7 所示。

主干特征提取网络 Backbone 的功能是将输入的  $416 \times 416 \times 3$  图片进行初步的特征提取,可以获得 shape 分别为  $13 \times 13$ 、 $26 \times 26$ 、 $52 \times 52$  的 3 个初步的有效特征层,他们包含着不同维度的语义信息。因此,可以通过将这三个有效特征层在输入加强特征提取网络前进行替换,来达到替换网络的目的。

加强特征提取网络对应图 7 的空间金字塔池化(SPP)和聚合网络(PANet),首先 SPP 对输入的  $13 \times 13$  特征层进行不同尺度的池化处理<sup>[17]</sup>,在经过级联后进行  $3 \times 3$  卷积,最后进入 PANet 中与  $26 \times 26$ 、 $52 \times 52$  特征层进行特征融

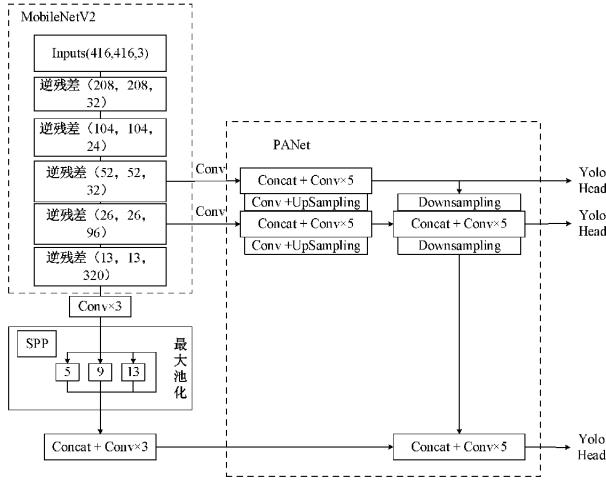


图 7 MobileNetV2-Yolov4-lite 算法网络结构

合, 提取出更好的特征进行输出。由于其参数量主要集中在标准的  $3 \times 3$  卷积上面, 为了进一步减少参数量, 我们可以使用一个  $3 \times 3$  的深度可分离卷积加上一个  $1 \times 1$  的标准卷积代替 Yolov4 中 PANet 用到的标准  $3 \times 3$  卷积。

最后, 通过获取预测框的 4 个坐标 top、left、bottom、right, 利用矩阵的形式对光伏板识别结果进行截取并放在黑幕下。

### 2.3 光伏板热斑分割模型

#### 1) DeepLabV3+分割模型

DeepLabV3+是在 DeepLabV3 的基础上增加了一个解码器模块来获得更清晰的分割结果。DeepLabV3+的编码器部分(encoder)通过主干网络 Xception 模型中不同通道的深度可分离卷积层提取图像特征信息, 利用空间金字塔池化(SPP)进行特征提取。在解码器(decoder)中将低级特征与高级特征进行融合。decoder 和 SPP 中都使用深度可分离卷积代替了空洞卷积, 减少了计算参数, 从而实现了更快、更强的编解码器网络。

在 DeepLabV3+中常使用交叉熵作为损失函数, 计算如式(5)所示。

$$Loss = -\frac{1}{WH} \sum_i^H \sum_j^W \log p_{ij} \quad (5)$$

式中:  $H$  为图像的高度;  $W$  为图像的宽度;  $p_{ij}$  为位置  $(i, j)$  处对应于该处标签的预测概率。

#### 2) DeepLabV3+的改进

本实验采用基于 MobileNetV2 网络优化的 DeepLabV3+ 网络模型(以下简称 DeepLabV3+\_MobileNetV2), 整体架构如图 8 所示。利用 MobileNetV2 代替 Xception 网络作为主干特征提取网络, 优化 DeepLabV3+ 算法, 既能大大减少模型参数量, 实现模型的轻量化设计, 又可以保证深度卷积在高维度完成特征提取, 提升模型计算性能, 而且采用语义分割模型 DeepLabV3+ 可以对光伏板热斑进行像素级别的分割, 解决光伏板反光的虚假热斑影响。

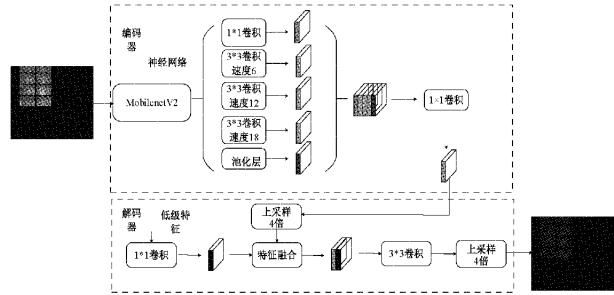


图 8 DeeplabV3+\_MobileNetV2 网络结构

在编码器中, 利用 MobileNetV2 网络和速率分别为 6、12 和 18 的空洞卷积进行热斑的特征提取, 合并后进行  $1 \times 1$  卷积压缩, 输出高级特征; 在解码器中, 将编码器中的低级特征进行  $1 \times 1$  卷积降维之后与高级特征进行特征融合, 恢复目标边界, 之后经过  $3 \times 3$  卷积和 4 倍上采样解码出最终的预测图。

在编码器中需要对输入图像进行下采样, 下采样的作用不仅使图像符合显示区域的大小还可使输出图像变小<sup>[18]</sup>, 因此 16 倍下采样更适合于目标较大的分割, 对于光伏板热斑这种小目标误差很大, 故将下采样倍数由 16 修改为 8, 提高分割效果。

在光伏板热斑分割上, 由于热斑较小, 前景极度不平衡, 普通交叉熵损失函数无法解决这种极度不平衡的问题, 所以本文使用梯子损失(Dice Loss)函数代替交叉熵损失函数的方式<sup>[19]</sup>, 来提高分割精度, Dice Loss 如式(6)所示。

$$DL_{(p)} = 1 - \frac{\sum_1^I \sum_1^N p_{ij} g_{ij}}{\sum_1^N P_{ij} + \sum_1^N g_{ij}} \quad (6)$$

式中:  $N$  为像素点个数;  $I$  为种类个数, 设为 2;  $p_{ij}$  为像素点预测为种类的概率;  $g_{ij}$  为像素点  $j$  属于  $i$  的标签值。

## 3 检测结果与分析

### 3.1 试验设置

#### 1) 训练和测试平台

本试验处理平台为 Inter(R) Xeon(R) Bronze 3204 CPU, 主频 1.90 GHz, 32 GB 内存, 显卡为 NVIDIA Quadro P5000 的工作站, 操作系统为 windows10 64 位, 利用 pytorch 框架进行环境搭建。

#### 2) 迁移学习

由于数据集较小, 直接训练模型收敛效果可能不佳, 达不到高识别率。因此可以在一个完备的数据集上训练好的模型权重通过迁移学习<sup>[20]</sup> 应用到光伏板识别和热斑分割上, 这样就可以在数据集较小的情况下使模型快速收敛, 实现更高的准确率。

#### 3) 训练参数

##### (1) 光伏板识别模型训练

将数据扩充后的 7 785 张光伏板红外图片按照训练集

与验证集比例 8:2 进行划分, 用来进行光伏板识别模型的训练。训练过程分为两个阶段, 分别为冻结阶段和解冻阶段, 冻结阶段主干网络被冻结, 特征提取网络不发生改变, 解冻阶段主干不被冻结, 特征提取网络改变。使用已经训练好的预训练权重, 在冻结阶段初始学习率为  $1 \times 10^{-3}$ , 训练 50 次, 解冻阶段初始学习率为  $1 \times 10^{-4}$ , 训练 50 次, 共 100 次。每个模型进行 3 次的重复试验, 取平均值作为试验结果。

### (2) 热斑分割模型训练

在光伏板识别结果图片中, 具有热斑的图片 1 610 张按照训练集与验证集比例 9:1 进行划分, 用来进行热斑分割模型的训练。使用已经训练好的预训练权重, 在冻结阶段初始学习率为  $1 \times 10^{-3}$ , 训练 35 次, 解冻阶段初始学习率为  $1 \times 10^{-4}$ , 训练 35 次, 共 70 次。采用试验 3 次取各指标平均值作为结果。

## 3.2 光伏板检测结果与分析

### 1) 判别标准

本文将预测结果与实际目标的交并比( IOU )阈值设置为 0.5, 当 IOU 值大于 0.5 时为正确预测。分别用平均检测精度(AP)、召回率(recall)来衡量不同算法的预测效果, 用 FPS 和模型大小来衡量模型实际应用的可行性, FPS 是每秒检测图片的帧数, 模型大小由模型参数量决定, 各指标定义如式(7)~(10)所示。

$$\text{Precision} = \frac{tp}{tp + fp} \quad (7)$$

$$\text{recall} = \frac{tp}{tp + fn} \quad (8)$$

$$AP = \int_0^{\text{recall}} \text{precision} d_{\text{recall}} \quad (9)$$

$$FPS = \frac{s}{t} \quad (10)$$

式中:  $tp$  为实际是正样本而且被预测为正样本的数量;  $fp$  为实际是正样本但被预测为负样本的数量;  $fn$  为实际是负样本但被预测为正样本的数量;  $s$  为处理的图像数量;  $t$  为处理图像所需时间。

### 2) 网络对模型性能的影响

通过比较 Faster-rcnn、Yolov4-Tiny、Yolov5 算法验证本文检测模型的效果。然后分别用 MobileNetV1、MobileNetV2、MobileNetV3 网络对 Yolov4 的主干网络进行替换来验证模型改进后的效果, 各模型简记为 Yolov4-V1、Yolov4-V2、Yolov4-V3。对比各算法的 AP、FPS、Precision、模型大小对本文所提出的 MobileNetV2-Yolov4-lite 网络模型进行性能检测, 试验结果如表 1、2 所示。

由表 1 可知, 两阶段检测算法 Faster-rcnn 不仅精度低而且识别速度最慢; Yolov4-Tiny 在速度上有了极大的提高, 为 42 帧/s, 但其精度下降, 不适用于故障检测; Yolov5s 在本文数据集中效果中规中矩, 虽然模型最小, 但是精度需要提高; Yolov4 算法 AP 指标最高, 可提升空间大, 故本文选择 Yolov4 作为基本模型进行改进。

表 1 不同模型在光伏板红外图像数据集上的效果对比

模型	AP/%	Recall/%	FPS 帧/s	模型大小/M
Faster-rcnn	97.9	97.63	7.7	108
Yolov4-Tiny	96.94	95.42	42	22.4
Yolov5s	95.58	96.58	20.25	27
Yolov4	99.66	98.57	13.7	244

表 2 替换网络后模型效果对比

模型	AP/%	Recall/%	FPS 帧/s	模型大小/M
Yolov4	99.66	98.57	13.7	244
Yolov4-V1	99.62	98.03	18.2	51
Yolov4-V2	99.56	98.91	22.1	46.4
Yolov4-V3	99.61	97.89	15.9	53.6

由表 2 可知, 不同模型在 AP 上表现都较好, Yolov4 算法 AP 指标最高, 为 99.66%; 在 recall 上, 各模型差距不大, 识别效果均满足目标检测要求, 但是在 FPS 上, 本文 Yolov4-V2 最高, 为 22.1 帧/s, 比 Yolov4 高出了 8.4 帧/s, 比 Yolov4-V1 高出了 3.9 帧/s, 比 Yolov4-V3 高出了 6.2 帧/s; 在模型大小上, 本文 Yolov4-V2 最小, 为 46.4 M, 比 Yolov4-V3 小 7.2 M, 比 Yolov4-V1 小 4.6 M。因此, 本文 MobileNetV2-Yolov4-lite 模型在保证精度的同时, 在检测速度和计算参数上均有较大优势, 可以适用于实时检测和硬件资源较低的情况。在本文 MobileNetV2-Yolov4-lite 模型下对光伏板红外图像数据集训练与测试, 损失函数衰减曲线如图 9 所示, 光伏板识别与截取结果如图 10 所示。

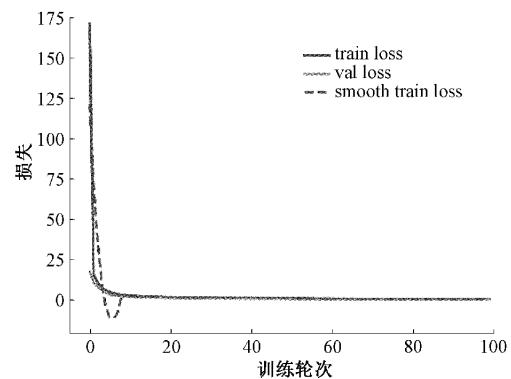


图 9 损失函数曲线

## 3.3 光伏板热斑分割结果与分析

### 1) 判别标准

本文将阈值设置为 0.5, 当阈值大于 0.5 时为正确预测。本文采用平均像素精度(MPA)和平均交并比(MIoU)来衡量分割效果, 用 FPS 和模型大小来对实际应用是否可行进行分析, 各指标定义如式(11)、(12)所示。

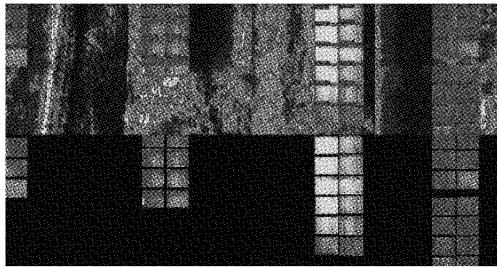


图 10 光伏板识别结果

$$\text{MPA} = \frac{1}{n} \sum_{i=0}^n \frac{R_{ii}}{\sum_{j=0}^n R_{ij}} \quad (11)$$

$$\text{MIoU} = \frac{1}{n} \sum_{i=0}^n \frac{R_{ii}}{\sum_{j=0}^n R_{ij} + \sum_{j=0}^n R_{ji} - R_{ii}} \quad (12)$$

式中:  $R_{ij}$  为真实值为  $i$  但被预测为  $j$  的像素数;  $n$  为试验类别数目。

## 2) 检测结果与分析

通过对不同语义分割模型的检测效果,选出最优模型进行改进,对比结果如表 3 所示。

表 3 不同模型各指标值的大小

模型	MPA/%	MIoU/%	FPS 帧/s	模型量/M
Deeplabv3+	73.26	71.34	13.7	209
PSPnet	70.88	68.54	13.99	188

由表 3 可知,使用原始网络的两种模型在 FPS 和模型大小上差距不大,而且在 MPA 和 MIoU 上均不高,但为了更好的识别光伏板热斑,本文选用精度更高的 Deeplabv3+ 作为基础模型进行了改进。

为验证不同修改方法对模型的影响,以 DeeplabV3+ 为基础模型,分别采用主干网络替换为 MobileNetV2、修改下采样倍数 16 为 8、修改损失函数为 Dice Loss 函数的方法,开展训练和测试试验,修改方式如表 4 所示。

表 4 不同处理方法

处理方法	模型				
	A	B	C	D	E
Xception 网络	√				
MobileNetV2		√	√	√	√
下采样 16 倍	√	√		√	
下采样 8 倍			√		√
交叉熵 loss	√	√	√		
Dice loss				√	√

分别对表 4 不同处理方法的 5 种模型进行试验,通过对比各算法 MPA、MIoU、FPS、模型大小对本文所提出的模型进行性能检测,试验结果如表 5 所示。

表 5 不同方法下各指标值的大小

模型	MPA %	MIoU %	FPS 帧/s	模型量 M
A	73.26	71.34	13.7	209
B	92.03	80.73	26.6	22.3
C	94.95	84.31	24.1	22.3
D	93.21	81.66	26.8	22.3
E	95.99	85.58	24.5	22.3

由表 5 可知,替换主干网络为 MobileNetV2,B 模型比 A 在各项指标上均有很大提升,MPA 提升 18.77%,MIoU 提升 9.36%,FPS 提高近 1 倍,模型缩小了 186.7 M,表明替换主干网络后效果很好。在下采样修改为 8 后,C 比 B 模型虽然在 FPS 上下降 2.5 帧/s,但是在 MPA 和 MIoU 上,均有提升,分别为 2.92% 和 3.58%,可以看出下采样倍数的修改对模型分割能力的提高。在修改 Loss 函数为两种结合后,D 比 B 模型在各指标上均有提高,FPS 提高 0.2 帧/s,MPA 提高 1.18%,MIoU 提高 0.93%,因此,修改损失函数对本文模型分割效果有明显提升。模型 E 不仅修改了下采样倍数还修改了损失函数,综合比较下,在预测精度和模型大小上均有较大优势,可以适用于实时检测和硬件资源较低的情况。

在本文 DeeplabV3+\_MobileNetV2 模型下对光伏板红外图像数据集训练与测试,损失函数对比曲线如图 11 所示,热斑分割结果图像如图 12 所示,其中图 12(a)列为分割前图像,图 12(b)列为分割后带有光伏板图像,图 12(c)列为分割后去除光伏板只显示热斑的图像。

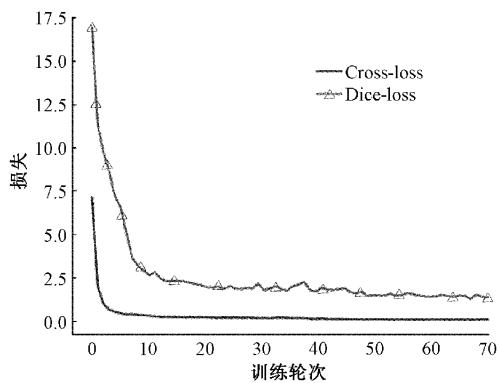
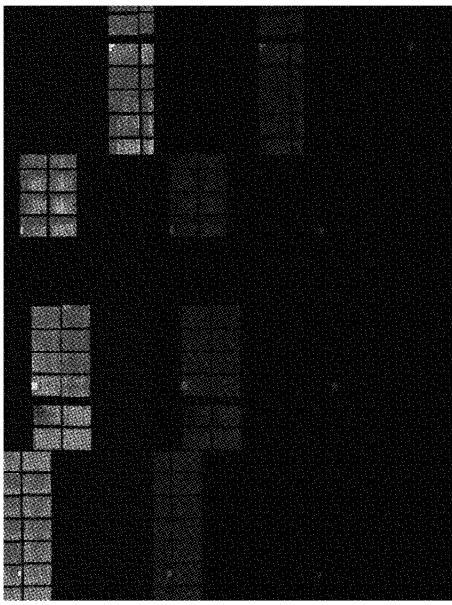


图 11 损失函数对比曲线



(a) 分割前原图 (b) 分割后带背景 (c) 分割后去除背景

图 12 热斑分割结果

## 4 结 论

研究设计的 Yolov4 + MobileNetV2 + Deeplabv3 + 光伏板热斑识别模型可有效实现光伏板目标识别与热斑定位。红外图像光伏板识别模型中, 基于改进的 Yolov4 算法, 对经过数据增广的光伏板红外图像数据集进行测试, 综合考虑准确率、计算速度和参数量, 优选了 Yolov4 + MobileNetV2 模型, 解决了复杂背景下光伏板的识别与截取困难问题。在红外图像热斑分割模型中, 替换主干网络为 MobileNetV2, 下采样倍数改为 8、使用 Dice 损失函数的 DeeplabV3 + \_MobileNetV2 模型, 解决了光伏板反光的虚假热斑影响问题, 在本文验证集上, 检测精度及速度均能满足实时检测的需求。在接下来的研究中, 会考虑对热斑进行分类, 进行热斑成因分析, 并进一步提高热斑识别精度与速度。

## 参考文献

- [1] 陈泽雄, 张新民, 王雪峰, 等. 分布式光伏电站接入配电网的分布鲁棒优化配置方法[J]. 电力系统保护与控制, 2021, 49(13): 30-42.
- [2] 陈杨, 何勇. 基于农村分布式光伏电站勘测的小型无人机倾斜摄影系统及试验[J]. 农业工程学报, 2019, 35(22): 305-313.
- [3] 范思远, 王煜, 曹生现, 等. 积灰对光伏组件输出特性影响建模与分析[J]. 仪器仪表学报, 2021, 42(4): 83-91.
- [4] 王道累, 李超, 李明山, 等. 基于深度卷积神经网络的光伏组件热斑检测[J]. 太阳能学报, 2022, 43(1): 412-417.
- [5] 蒋琳, 苏建徽, 李欣, 等. 基于可见光和红外热图像融合的光伏阵列热斑检测方法[J]. 太阳能学报, 2022, 43(1): 393-397.
- [6] 陈功, 蔡磊, 张琳, 等. 光伏热斑模拟建模及热成像分析[J]. 电子测量与仪器学报, 2021, 248(8): 191-197.
- [7] 柳扬, 陈美珍, 徐胜彬, 等. 基于热成像与灰度转换技术的光伏阵列缺陷检测方法[J]. 电子测量技术, 2021, 44(11): 96-102.
- [8] 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.
- [9] 王培珍. 光伏阵列故障状态的识别研究[D]. 合肥: 合肥工业大学, 2005: 19-22.
- [10] 孙海蓉, 潘子杰, 晏勇. 基于深度卷积自编码网络的小样本光伏热斑识别与定位[J]. 华北电力大学学报(自然科学版), 2021, 48(4): 91-98.
- [11] 孙海蓉, 李号. 基于深度迁移学习的小样本光伏热斑识别方法[J]. 太阳能学报, 2022, 43(1): 406-411.
- [12] 王春. 基于生成对抗网络的光伏组件热斑识别方法研究[D]. 保定: 华北电力大学, 2020: 30-34.
- [13] 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: 40-48.
- [14] 周云成, 许童羽, 郑伟, 等. 基于深度卷积神经网络的番茄主要器官分类识别方法[J]. 农业工程学报, 2017, 33(15): 219-226.
- [15] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度学习网络的输电线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37-44.
- [16] 范佳佳. 面向交通标志的目标检测算法研究[D]. 合肥: 安徽建筑大学, 2021: 21-25.
- [17] 叶子勋, 张红英. YOLOv4 口罩检测算法的轻量化改进[J]. 计算机工程与应用, 2021, 57(17): 157-168.
- [18] 李力, 英聪, 李俊, 等. 无人机图像去雾处理速度优化研究[J]. 遥感信息, 2020, 35(6): 49-55.
- [19] 蔡畅, 陈军波, 陈心浩. 基于改进 U-Net 方法的脑肿瘤磁共振图像分割[J]. 中南民族大学学报(自然科学版), 2021, 40(4): 417-423.
- [20] 黎英, 宋佩华. 迁移学习在医学图像分类中的研究进展[J]. 中国图象图形学报, 2022, 27(3): 672-686.

## 作者简介

管宽岐, 硕士研究生, 主要研究方向为图像处理与缺陷检测方向研究。

E-mail: 936903073@qq.com

蔺雨桐, 硕士研究生, 主要研究方向为图像处理与目标检测方向研究。

E-mail: 982207754@qq.com

赵雨薇, 硕士研究生, 主要研究方向为图像分割与杂草识别方向研究。

E-mail: 1609967745@qq.com

秦列列, 硕士研究生, 主要研究方向为高光谱图像地物识别方向研究。

E-mail: 809267831@qq.com

张楠楠, 博士, 主要研究方向为交直流微电网控制与优化方面研究。

E-mail: zhangnannan@syau.edu.cn

曹英丽(通信作者), 博士, 主要研究方向为农业信息化方面研究。

E-mail: caoyingli@163.com