

DOI: 10.13382/j.jemi.B2508105

基于轻量化改进 YOLOv8 的光伏阵列表面缺陷检测*

张彼德¹ 王泽林¹ 廖其龙² 阎铁生¹ 林 夏¹ 汪瑞杰¹

(1. 西华大学电气与电子信息学院 成都 610039; 2. 攀枝花学院电气信息工程学院 攀枝花 617000)

摘要:针对现有目标检测方法在光伏阵列表面缺陷检测中精度较低且模型过于庞大,难以适用于轻量化无人机检测设备的现状,提出了一种改进的轻量化 YOLOv8 模型。使用跨阶段部分异构卷积网络(CSPHet)模块,在减少模型参数、提高运行效率的同时,保证了对特征的提取能力;引入部分自注意力(PSA)机制,将全局信息融入特征图中,提升网络对目标与背景的辨别能力,同时减少噪声对目标定位和分类的影响;采用跨尺度特征融合模块(CCFM)颈部结构,通过调整模型的输出通道数,降低了模型的复杂度,从而实现了更加高效且轻量化的网络架构;加入全局感知模块自注意力卷积混合(ACmix),增强模型对全局的感知能力,减少了无关信息的干扰,提高了模型的鲁棒性。实验结果表明,改进后的 YOLOv8 模型参数量减少 37%,计算量减少 27%,且检测平均精度均值(mAP)mAP@0.5 提升至 81.2%。显著降低了参数量和计算量,实现轻量化的同时,提升了检测精度。与其他模型相比,更加适合部署在轻量化无人机设备上,用于光伏阵列表面缺陷的目标检测。

关键词: 光伏阵列; 缺陷检测; YOLOv8; 轻量化; 检测精度; 无人机

中图分类号: TM615; TN06

文献标识码: A

国家标准学科分类代码: 470.40

Surface defect detection of photovoltaic array based on lightweight improvement of YOLOv8

Zhang Bide¹ Wang Zelin¹ Liao Qilong² Yan Tiesheng¹ Lin Xia¹ Wang Ruijie¹

(1. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China;

2. School of Electrical and Information Engineering, Panzhihua University, Panzhihua 617000, China)

Abstract: Aiming at the current situation that the existing target detection method has low accuracy and the model is too large in the surface defect detection of photovoltaic array, it is difficult to apply to the lightweight UAV detection equipment. An improved lightweight YOLOv8 model is proposed. The use of CSPHet module ensures the ability to extract features while reducing model parameters and improving operating efficiency. The PSA attention mechanism is introduced to integrate the global information into the feature map, which improves the network's ability to distinguish the target and background, and reduces the influence of noise on target location and classification. The CCFM neck structure is adopted, and the complexity of the model is reduced by adjusting the number of output channels of the model, so as to achieve a more efficient and lightweight network architecture. The global sensing module ACmix is added to enhance the global sensing ability of the model, reduce the interference of irrelevant information, and improve the robustness of the model. The experimental results show that the parameters of the improved YOLOv8 model are reduced by 37%, the calculation amount is reduced by 27%, and the detection accuracy mAP@0.5 is increased to 81.2%. The parameter quantity and calculation amount are significantly reduced, and the detection accuracy is improved while achieving lightweight. Compared with other models, it is more suitable for deployment on lightweight UAV equipment for target detection of surface defects of photovoltaic arrays.

Keywords: photovoltaic array; defect detection; YOLOv8; lightweight; detection accuracy; UAV

0 引言

随着“碳中和”和“碳达峰”目标的提出^[1],全球正在掀起一场新能源的革命。这场革命的核心理念是减少对化石燃料的依赖,降低温室气体的排放,并提升可再生能源在能源消费中的比重。光伏阵列发电作为新能源发展的重要组成部分,在这一进程中发挥着举足轻重的作用,因此,当前各行各业都在广泛应用光伏发电技术。但是,光伏阵列一般放置于户外,在常年累月的风吹日晒和外界物理因素影响下,容易发生各种表面缺陷,例如鸟粪、碎裂、积污和积雪等。这些缺陷若不及时处理,可能会导致一些更严重的故障,如热斑、能量损失和系统故障等,因此对光伏阵列表面缺陷的检测至关重要^[2],可以提高光伏系统的安全性和稳定性。

直接依靠人工检查的方法,成本高昂、效率低下,并且受检查人员主观判断的影响,存在误检和漏检的风险。随着深度学习的不断发展,当前其已广泛应用于计算机视觉领域。越来越多的研究人员通过使用深度学习的方法对光伏阵列表面缺陷进行识别与诊断。计算机视觉领域常用的深度学习方法有两种,一种是双阶段的目标检测算法,以 Faste-RCNN (faster regions with convolutional neural networks)^[3]和区域卷积神经网络(RCNN)为主要代表;另一种是单阶段的目标检测算法,以单次多框检测器(single shot multibox detector, SSD)^[4]和 YOLO (you only look once)^[5]系列为主要代表。在双阶段的目标检测中,冯小雨等^[6]基于 Faster-RCNN 提出了膨胀积累、区域放大等一系列的改进机制,提高了 Faster-RCNN 对小目标的检测速度和精度。张琦等^[7]通过引入多个内置子网络和利用加速鲁棒特征(speeded up robust features, SURF)算法,实现目标的快速检测,但双阶段目标检测模型普遍存在参数数量和计算量大,检测速度慢的问题。在单阶段的目标检测中,唐聪等^[8]基于 SSD 提出一种多视窗 SSD 模型,改善了模型对小目标的检测性能,但网络过于庞大,不适合部署在轻量化设备中。郭建等^[9]提出了一种优化 YOLOv5 模型的方法,在其网络结构中,采用了多尺度特征融合模块加权双向特征金字塔网络(BiFPN),通过融合不同尺度的特征来减少复杂背景的干扰。同时,在模型的输出端增加了小目标检测头,以减少微小信息的丢失,从而有效提高了模型的准确率,尽管如此,模型的参数量仍较大。赵会鹏等^[10]提出了一种改进的 YOLOv8 模型,通过引入轻量化卷积 GhostConv 和 GhostC2f 模块,有效减少了模型的参数量。然而,模型的准确率仍有进一步优化的潜力。胡森^[11]针对 YOLOv4 检测精度不高的问题,分别将 SKnet 注意力机制应用于骨干层、颈部层和头部层进行实验。实验结果表明,加入

骨干层能够显著提升网络的准确率,但同时计算量也有所增加。徐威等^[12]基于 YOLOv7-tiny 算法进行改进,引入了轻量化卷积 PSDConv 和 DFC (decoupled fully connected) 注意力机制,并将 Clou 损失函数替换为 EIoU^[13]损失函数,从而提高了模型的精度,但其轻量化效果并不显著。石欣等^[14]基于 YOLOv4 提出了一种针对小目标检测的方法,通过引入改进特征金字塔和特征自适应融合方法,以提取小目标的细粒度特征并增强语义信息的关联。同时,结合 ESRGAN (enhanced super-resolution generative adversarial networks) 网络提高了检测精度。尽管该方法提升了网络精度,但其网络结构相对复杂。

以上方法在提升模型检测精度或减少模型参数量和计算量方面取得了一定成效,但未能同时兼顾模型的轻量化与精度提升。因此,这些目标检测算法仍有进一步优化空间。

在对光伏阵列表面缺陷进行目标检测时,若将模型部署在轻量化无人机检测设备上,需实现模型轻量化的同时确保具有较高的检测精度。因此,提出了一种基于轻量化改进 YOLOv8 的光伏阵列表面缺陷检测模型。首先,使用轻量化跨阶段部分异构卷积网络(cross stage partial heterogeneous convolution network, CSPHet) 模块代替基准模型中的 C2f 模块,减少模型参数量和计算量。其次,在主干网络 SPPF 模块后引入部分自注意力(partial self-attention, PSA) 机制,增强网络对目标和背景的辨别能力。再将基准模型的颈部结构改为跨尺度特征融合模块(cross-scale feature fusion module, CCFM) 结构,增强模型的特征融合能力,减少输出时冗余的语义信息和模型复杂度。最后,加入全局感知模块自注意力卷积混合(attention convolution mix, ACmix),增强模型对全局特征和局部特征的提取能力。

1 YOLOv8 网络介绍

YOLOv8^[15]是由 Ultralytics 公司于 2023 年发布的一种单阶段目标检测算法,广泛应用于图像分类、目标检测、实例分割和轨迹追踪等计算机视觉任务。本文采用了目标检测算法,该算法提供了 5 种不同大小的模型规格, n、s、m、l 和 x。为了更好地实现集成化,选择对 n 规格下的 YOLOv8 模型进行改进,该模型具有轻量、高效和实时性强的优点。YOLOv8 目标检测算法网络结构由输入层(input)、主干层(backbone)、颈部层(neck)和头部层(head)4 部分组成,结构如图 1 所示。

Input 层网络有数据增强^[16]的功能,如 Mosaic 和 Mixup 等数据增强方法,这些方法可以增加数据的多样性,从而提高网络的泛化性和鲁棒性。Backbone 层由

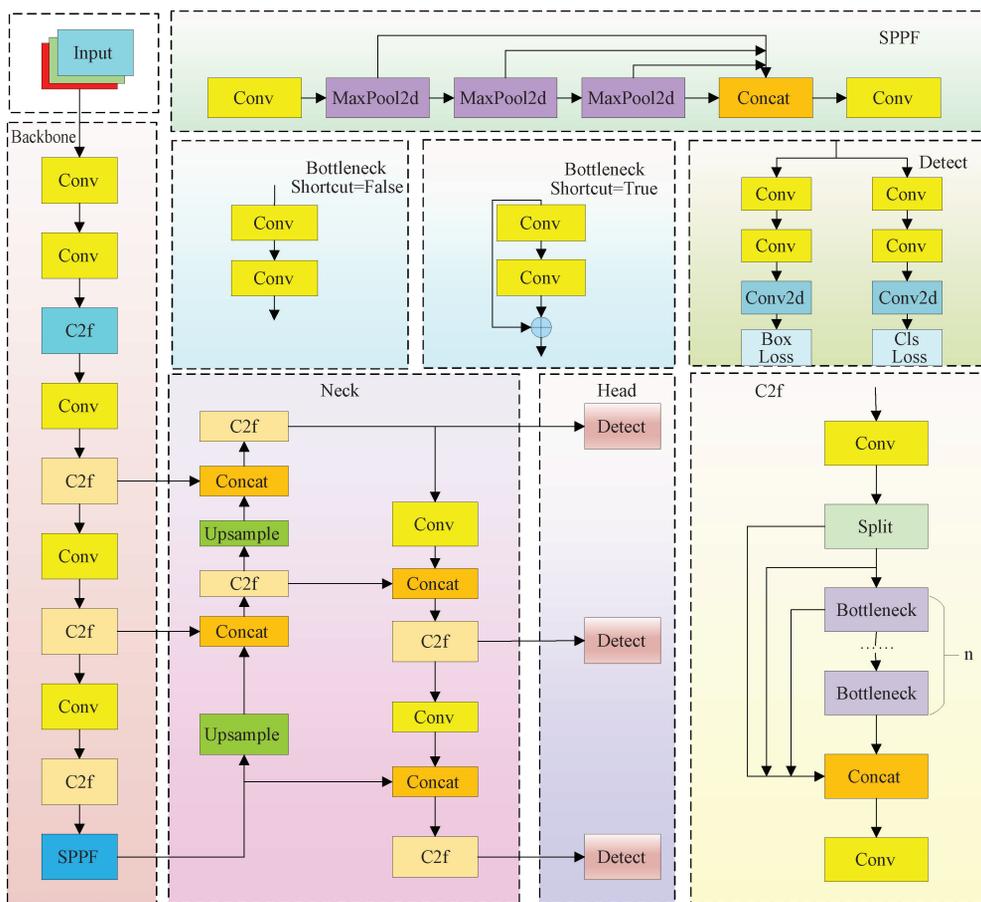


图 1 YOLOv8 网络结构

Fig. 1 YOLOV8 network structure diagram

Conv、C2f 和 SPPF 3 部分组成,其中 Conv 用于下采样, C2f 负责特征提取, SPPF 则用于增加网络的感受野。 Neck 层采用特征金字塔网络与路径聚合网络 (feature pyramid network-path aggregation network, FPN-PAN) 相结合的结构进行特征融合, FPN 网络自顶向下进行语义的传输, PAN 网络自底向上进行位置的传输, 并且该结构使用了跨层连接的方法, 将浅层特征和深层特征进行融合, 从而得到同时具有位置信息和语义信息的特征层。 Head 层将 Neck 层输出的特征图输入该层进行处理, 得到每个像素点的最终预测结果, 包括类别、置信度和位置信息。 最后, 对所有预测框进行置信度筛选和非极大值抑制, 从而获得最终图像上展示的预测框及其相关信息。

2 YOLOv8 的改进算法

在进行光伏阵列表面缺陷检测时, 为了降低对设备的要求和满足轻量化的工业需求。 提出了一种基于 YOLOv8 改进的轻量化模型。 该模型很好的解决了以往光伏阵列表面缺陷检测算法参数数量和计算量过于庞大,

普通设备难以集成化的问题。 显著降低了参数量和计算量, 同时提高了模型的检测精度。

改进后的模型结构如图 2 所示, 主要包含 4 个改进部分。

1) 使用 CSPHet 模块代替 C2f 模块。 CSPHet 模块采用了异构内核卷积的思想, 将 Bottleneck 模块中的普通卷积替换成异构卷积 (heterogeneous convolution, HetConv), 在减少参数量和计算量的同时, 依然能够保持较高的准确率。

2) 引入 PSA 机制, 增强模型的全局建模能力, 使模型可以在不显著增加计算成本的情况下, 提升模型的性能。

3) 使用轻量化的 CCFM 替代 YOLOv8 中的 PAN-FPN 结构, 不仅能够降低参数量, 还能增强模型对尺度变化的适应性和小目标检测能力。

4) 在特征融合中加入 ACmix 全局感知模块, 该模块结合了自注意力的全局感知能力和卷积捕获局部特征的优势, 从而在保持较低计算成本的同时, 提高了模型的检测精度。

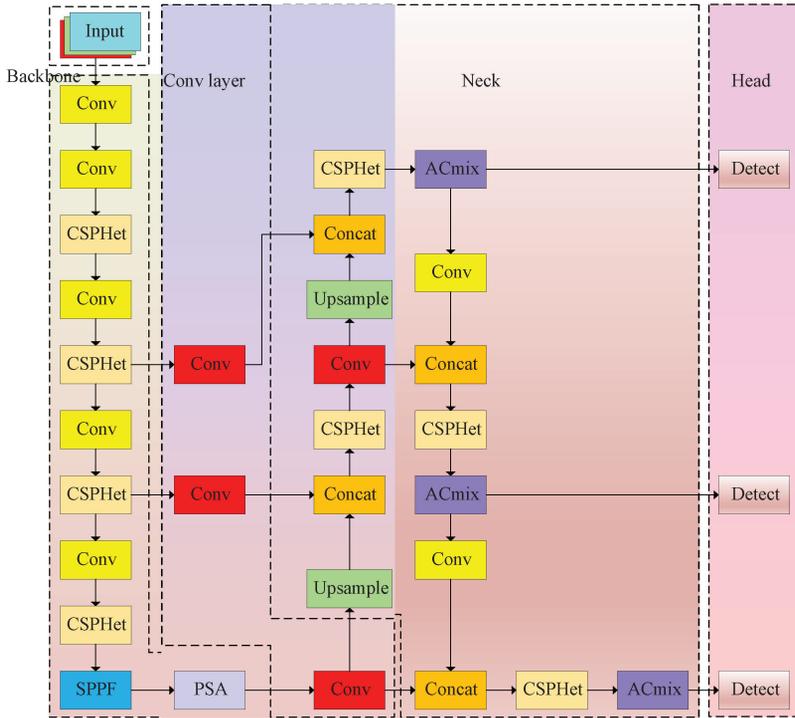


图 2 改进 YOLOv8 结构
Fig. 2 Improved YOLOv8 structure diagram

2.1 CSPHet 模块

在特征提取过程中,原 YOLOv8 中的 C2f 模块采用了固定大小的卷积核(3×3),这导致了特征的过度提取,增加了模型参数和计算量。基于此,使用 CSPHet 模块^[17]代替原 YOLOv8 中的 C2f 模块,该模块的优势在于使用了 HetConv,如图 3 所示, M 表示为输入通道的数量, P 表示多少个通道为一部分。HetConv 采用了不同大小的卷积核进行卷积,其中每部分只有 1 个 $k \times k$ 的卷积核(图 3 采用 3×3),其余都采用 1×1 的卷积核,这样做可以减少模型的参数量和计算量,同时也能保持网络的性能。

卷积核大小为 $k \times k$ 的标准卷积的计算量为:

$$FL_s = H \times W \times C_1 \times C_2 \times K \times K \quad (1)$$

式中: H 、 W 为输出特征图的高和宽; C_1 、 C_2 为输入和输出特征图的通道数。

异构内核卷积的计算量为:

$$FL_k = (H \times W \times C_1 \times C_2 \times K \times K) / P \quad (2)$$

$$FL_1 = (H \times W \times C_2) \times (C_1 - \frac{C_1}{P}) \quad (3)$$

$$FL_{HC} = FL_k + FL_1 \quad (4)$$

式(2)、(3)分别为异构卷积中 $k \times k$ 卷积核和 1×1 卷积核的计算量,故异构卷积相较于标准卷积的计算量减少比例为:

$$R_{Hetconv} = \frac{FL_k + FL_1}{FL_s} = \frac{1}{P} + \frac{(1 - 1/P)}{K^2} \quad (5)$$

从式(5)可以看出, HetConv 相较于标准卷积,计算量有明显的减少。其中, $k \times k$ 的卷积核能够获取大感受野特征,而 1×1 的卷积核则通过较少的参数量和计算量提取小感受野特征。在特征提取过程中,既能够捕捉全局特征,又能提取局部特征。因此,尽管参数量和计算量有所减少,模型仍能保持较高的准确率和性能优势。基于 HetConv 实现的 CSPHet 模块的结构如图 4 所示。

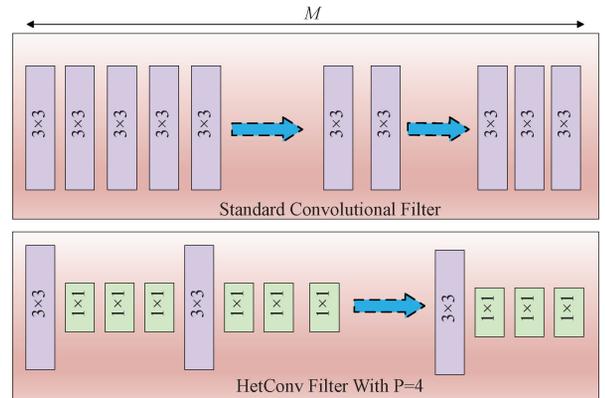


图 3 异构内核卷积结构

Fig. 3 Heterogeneous kernel convolution structure diagram

2.2 PSA 注意力机制

为了提高模型的全局建模能力,在主干网络的末端

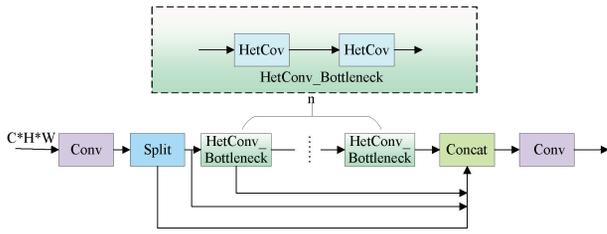


图 4 CSPHet 结构

Fig. 4 CSPHet structure diagram

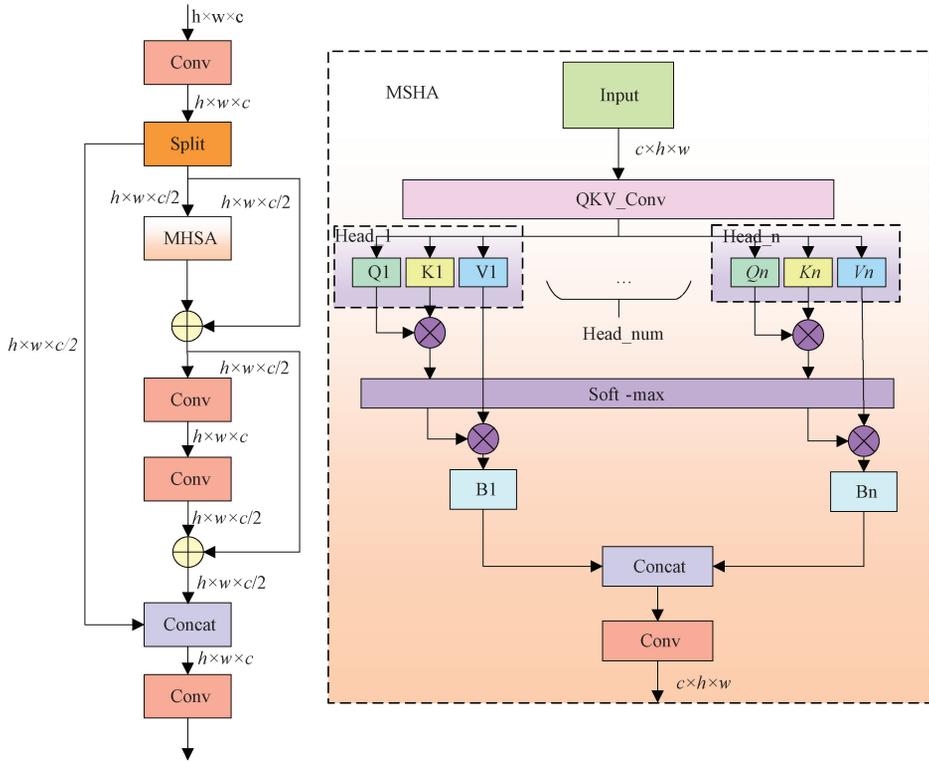


图 5 PSA 注意力机制结构

Fig. 5 Structure diagram of PSA attention mechanism

个矩阵时,为了降低复杂度和计算成本,使用 QKV_Conv 卷积计算得到一个大矩阵,然后在列方向上拆分成 Q 、 K 、 V 3 个矩阵;2)将 LayerNorm 归一化层替换为 BatchNorm 归一化层,从而提高了网络的计算速度。将自注意力模块和前馈网络输出的两部分特征相加,然后通过两个 1×1 卷积组成的 FFN 残差模块进行特征融合。接着,将得到的特征图与另一部分特征图沿通道方向拼接,最后通过 1×1 卷积进行进一步的特征提取。PSA 模块在不显著增加计算成本的前提下,将全局信息引入到特征图中,增强了网络对目标和背景的辨别能力,减少了噪音对定位和分类时的影响,从而提高了网络的性能。

2.3 CCFM 跨尺度特征融合

YOLOv8 颈部网络的作用是对提取后的特征进行融合和筛选。网络的主干部分将提取的特征,从浅层到深

引入了 PSA^[18] 注意力机制。PSA 注意力机制由自注意力模块和前馈网络构成,如图 5 所示,由于自注意力模块通常具有较高的参数量和计算量,因此,本文采用了一种高效的部分自注意力方式以降低其开销。

首先,通过 1×1 卷积和 Split 模块将特征图均匀分为两部分,其中一部分通过多头注意力模块 (multi-head self-attention, MSHA) 进行处理。与标准多头注意力模块不同,MSHA 采用了如下两项改进。1) 在计算 Q 、 K 、 V 3

层划分为 5 个不同大小的尺寸,浅层特征层具有较高的分辨率和丰富的位置信息,但其感受野小,适合检测小目标。相反,深层特征层具有更大的感受野和丰富的语义信息,但其分辨率低,适合检测大目标。YOLOv8 特征融合和筛选时,采用 PAN-FPN 的网络结构,FPN 是一种自上而下的采样方式,如图 6(a) 所示,该方式通过高层特征加强了大目标的语义信息,但是忽略了位置信息。PAN 则是在 FPN 的基础上增加了一条自下而上的采样路径,如图 6(b) 所示,从而弥补了位置信息的不足。尽管 YOLOv8 的 Neck 部分通过互补的方式,如图 6(c) 所示,实现了同时提取位置信息和语义信息,但该结构仍然存在改进的地方。1) 特征融合导致冗余信息过多,在同一层次的特征图中存在一些重复的信息,这些信息进行特征融合时,没能提高模型的性能,反而增加了模型的参

数量和计算量;2) 过度关注于小目标,虽然 PAN-FPN 提高了对小目标的检测能力,但是当目标较大时,这种小目标优化可能会导致模型精度的下降。

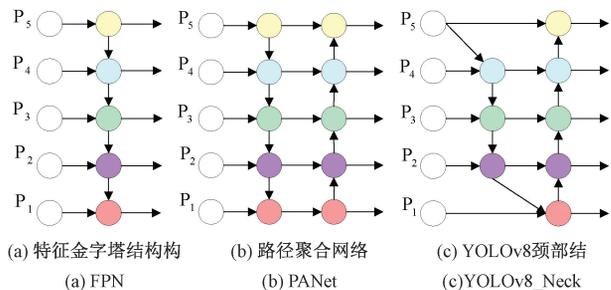


图 6 特征融合结构
Fig. 6 Feature fusion structure

为了解决以上问题,使用 CCFM^[19] 跨尺度特征融合的方式。该结构通过卷积操作将不同尺度的特征进行融合,从而增强特征图对目标尺寸变化的适应性,有效整合细节特征和上下文信息,提高了模型在不同大小目标检测中的检测精度。原始的 YOLOv8_Neck 结构进行特征融合时,同一层次的特征图中会存在冗余的相同特征,这不仅增加了模型计算负担,还未显著提高模型的性能,尤其是在融合深层特征时,过多的特征图通道数带来了大量的参数,且语义信息过于丰富减慢了模型的处理速度。CCFM 通过对深层特征图进行特征提取和筛选后,调整通道数为统一值,确保后续层在进行特征融合时具有相同的特征结构。这样既简化了模型结构,又减少了网络进行上采样和特征融合时的参数量和计算量。因此相较于原始的 YOLOv8_Neck 结构,CCFM 更加轻量化,拥有更少的计算量和参数量,CCFM 的结构如图 7 所示。

原 YOLOv8 主干提取的 B_3 、 B_4 、 B_5 特征层直接输入颈部网络进行拼接 (Concat), 这样造成了过多的冗余特征,增加了网络的计算量和参数量。CCFM 网络结构在将 B_3 、 B_4 、 B_5 特征层输入颈部网络进行拼接前,首先通过一个通道数为 256、卷积核大小为 1×1 的点卷积进行特征提取和筛选。这不仅增强了空间信息,还有效减少了冗余特征的输入,减轻了网络的计算负担。同理 P_4 特征层在与 B_3 和 N_3 特征层进行拼接前,也会先通过一个通道数为 256 的点卷积,进行特征的提取和筛选,减少冗余特征。在原 YOLOv8 中, N_3 、 N_4 、 N_5 特征层的输出通道数分别为 256、512 和 1 024。而在 CCFM 网络中,通过点卷积提前对特征进行了提取和筛选,因此在 N_3 、 N_4 、 N_5 特征层中统一将输出通道数减少至 256,从而提高了模型的计算效率和泛化性。

2.4 ACmix 全局感知模块

ACmix^[20] 是一种混合模块,结合了卷积运算和自注意力机制的优势,如图 8(a) 和 (b) 所示。其核心思想是,

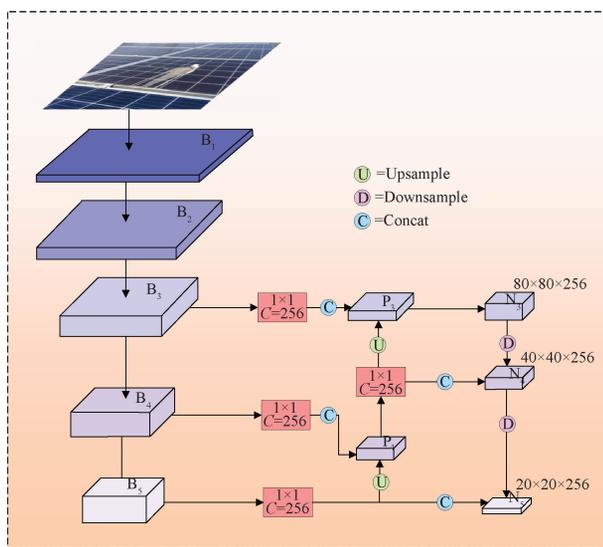


图 7 CCFM 结构
Fig. 7 CCFM structure diagram

标准卷积和自注意力机制中的大部分计算可以通过 1×1 卷积来实现,从而提高计算效率。ACmix 模块首先通过卷积操作对输入的特征图进行特征映射,生成了一组中间特征层。接着,卷积和自注意力机制分别对这些特征进行处理,并重新聚合得到最终的输出特征层。通过这种方式,ACmix 模块不仅通过卷积提取了局部特征,还通过自注意力机制捕获了全局特征,从而实现局部与全局信息的有效融合。

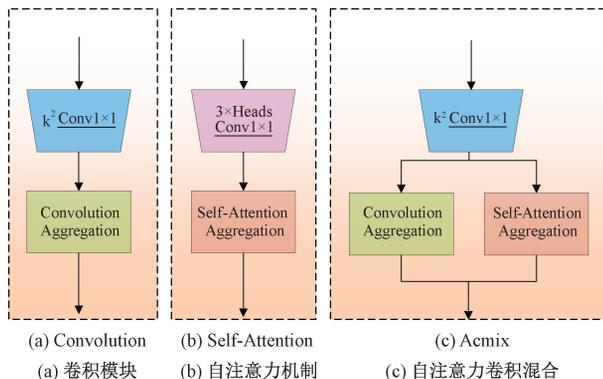


图 8 卷积和自注意力模块重构
Fig. 8 Convolution and self-attention module

ACmix 全局感知模块的优势在于两点。1) 融合了卷积和自注意力的两个优点,如图 8(c) 所示,提高了模型的鲁棒性和泛化性;2) 采用了运算分解与重构的方式,通过多个 1×1 卷积将输入的大特征图分解为多张小特征图输入到网络中进行特征提取,减少了模型的参数量和计算量,提高了模型的运算效率。

ACmix 结构如图 9 所示,包含两个阶段和两条路径。

第 1 阶段,输入特征通过 3 个 1×1 卷积进行投影,每个卷积输出 N 个片段,因此,最终得到一组包含 $3 \times N$ 个丰富信息的中间特征层。第 2 阶段,包含两条特征聚合路径,其中一条路径是自注意力路径,将中间层分为 N 组,每组中包含有 3 个特征层。每组特征层分别输入到一个 1×1 卷积中,得到 3 个特征图,这些特征图分别代表自注意力机制中的 Q, K 和 V 矩阵。通过这种方式,最终得到自注意力路径的输出 F_{att} 。另一条路径是卷积路径,为了使模

型轻量化,减少参数量,采用卷积代替全连接模块 (fully connected) 的方式生成 k^2 个特征图,再使用 Concat 沿通道方向进行拼接,最后通过卷积核大小为 $k \times k$ 的卷积进行特征提取和聚合生成最终卷积路径的输出 F_{conv} 。将两条路径的输出特征进行权重相加,得到 ACmix 模块最终的输出特征为 F_{out} 。

$$F_{out} = \alpha F_{conv} + \beta F_{att} \quad (6)$$

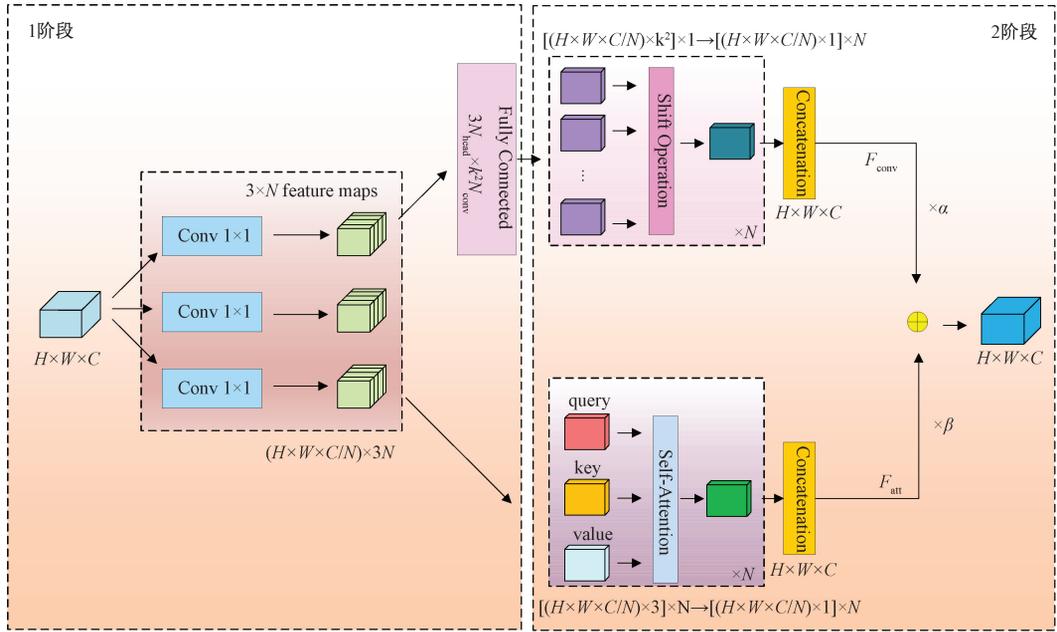


图 9 ACmix 结构

Fig. 9 ACmix structure diagram

3 实验结果与分析

3.1 实验配置

实验在操作系统为 Window11; 显卡 GPU 为 GTX4060, 内存为 16 G 的计算机上运行。Python 版本为 3.9, pytorch 版本为 1.12, CUDA 版本为 11.6, 训练时的 Batch_size 设置为 16, 总共进行 300 个 epochs 的训练。优化器选择 Adam, 初始学习率为 0.001, 动量设置为 0.937, 权重衰减为 0.0005。实验详细超参配置如表 1 所示。

表 1 实验环境

Table 1 Experimental environment

参数名称	参数值	参数名称	参数值
image_size	640	lrf	0.01
epochs	300	box	7.5
batch_size	16	cls	0.5
lr0	0.001	df1	1.5

3.2 实验数据集

由于现有的公开光伏阵列表面缺陷数据集较少,且大多数数据集难以直接用于目标检测任务,因此本研究通过在 Roboflow 网站采集光伏阵列表面缺陷图片,结合数据增强技术提升数据多样性,并使用 LabelImg 对图片进行手动标注,生成适用于训练的高质量数据集。该数据集包含的光伏阵列表面缺陷类别有鸟粪、碎裂、灰尘和积雪 4 类,实例如图 10 所示,共计 2 073 张图片,数据集详细信息如表 2 所示。将数据集按照 8 : 2 的比列随机划分为训练集和验证集。

表 2 数据集信息

Table 2 Dataset information

缺陷类型	标签	数量
鸟粪	bird_drop	509
碎裂	crack	515
灰尘	dust	553
积雪	snow	501

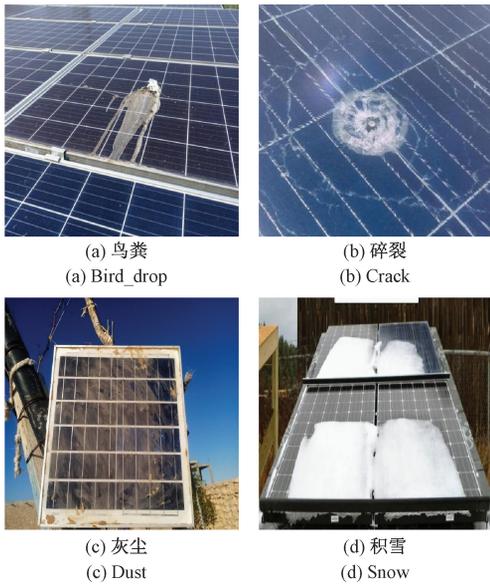


图 10 缺陷样本实例图

Fig. 10 Example of defect samples

3.3 评价指标

选取精确率 (precision, P)、召回率 (recall, R)、平均精度 (mean average precision, mAP)、模型参数量 (parameters)、以及模型计算量作为衡量模型的指标。

1) 精确率为模型正确输出的预测框数量与模型输出的所有预测框数量的比例。

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

2) 召回率为模型正确输出的预测框数量与真实目标框数量的比例。

$$R = \frac{TP}{TP + FN} \quad (8)$$

式中: TP 指的是正确预测的正样本数量; FP 指的是把负样本错误预判成正样本的数量, 即误判; FN 指的是把正样本错误预判成负样本的数量, 即漏判。

3) 平均精度均值指的是每个类别, 基于精确率-召回率曲线围成的面积值, 将每个类别计算出的面积值相加取平均。其中 $mAP@0.5$ 表示真实框与预测框交并比 (IoU) 值 >0.5 时为预测正确, 公式如式 (9) 所示。 $mAP@0.5 : 0.95$ 表示以 0.05 为步长, 求出 IoU 值从 0.5~0.95 的所有 mAP 值, 并相加取均值, 公式如式 (10) 所示。

$$mAP@0.5 = \frac{1}{c} \sum_{k=1}^c AP@0.5_k \quad (9)$$

$$mAP@0.5 : 0.95 = \frac{1}{10} mAP@0.5 +$$

$$\frac{1}{10} mAP@0.55 + \dots + \frac{1}{10} mAP@0.95 \quad (10)$$

式中: AP 指的是在 PR 曲线坐标图中围成的面积值。

4) 模型参数量用于衡量模型大小的参数量, 值越小说明模型越轻量化。

5) 模型计算量反应模型复杂度的变量, 值越小对使用设备硬件性能要求越低。

3.4 消融实验及分析

以 YOLOv8n 作为基准模型, 针对其进行不同模块的改进。为了验证各改进模块对模型性能的优化效果, 除改进模块不同外, 其他环境设置和超参数配置保持一致。为此, 设计了一系列消融实验, 如表 3 所示, 来评估各模块对模型性能的影响。

表 3 消融实验

Table 3 Ablation experiment

实验	CSPHet	PSA	CCFM	ACmix	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5 : 0.95/\%$	Parameters/($\times 10^6$)	计算量/GFLOPS
1	×	×	×	×	82.9	75.1	80.7	52.1	2.87	8.2
2	√	×	×	×	82.1	73.8	79.5	50.9	2.27	6.6
3	×	√	×	×	84.6	75.6	80.7	51.8	3.11	8.4
4	×	×	√	×	82.7	74.1	80.2	50.9	1.88	6.7
5	×	×	×	√	83.6	77.8	82.5	53.4	3.15	8.8
6	√	√	×	×	84.3	73	79.7	50.4	2.51	6.8
7	√	√	√	×	82.3	71.3	79.5	49.9	1.76	5.7
8	√	√	√	√	81.6	74.4	81.2	52.3	1.81	6

注: √表示使用了该模块; ×表示未使用该模块

实验 1 是未作任何修改的基准模型 YOLOv8n, 其 $mAP@0.5$ 、 $mAP@0.95$ 、参数量和计算量分别为 80.7%、52.1%、2.87 和 8.2。实验 2 引入 CSPHet 模块代替基准模型中的 C2f, 虽然准确率、召回率和平均精度 ($mAP@0.5$ 和 $mAP@0.5 : 0.95$) 有所下降, 但模型的参数量和计算量得到了优化, 分别减少了 21%、19.5%。实验 3 使

用了 PSA 注意力机制, 把模型的准确率和召回率分别提高到了 84.6%、75.6%。实验 4 采用了 CCFM 轻量化颈部结构, 在保证其他性能指标几乎不下降的情况下, 成功将参数量和计算量分别减少了 34.5% 和 18.3%。实验 5 引入 ACmix 模块, 虽然参数量和计算量有所增加, 但准确率、召回率和平均精度 ($mAP@0.5$ 和 $mAP@0.5 : 0.95$)

都得到了优化,分别提高到了 83.6%、77.8%、82.5% 和 53.4%。实验 6~8 逐步叠加不同模块,其中实验 8 为提出的最终模型,结合了 CSPHet、PSA、CCFM 和 ACmix 模块。从结果可以看出,相较于基准模型,最终模型在参数量和计算量上分别降低了 37% 和 27%。同时, $mAP@0.5$ 和 $mAP@0.5:0.95$ 均得到提升,分别达到 81.2% 和 52.3%。消融实验结果表明,改进后模型显著降低了参数量和计算量,同时提高了检测精度。

基准模型与改进后模型的热力对比如图 11 所示,可以看出,改进后模型相比于基准模型更加关注缺陷本身。平均精度对比如图 12 所示,改进后模型的 $mAP@0.5$ 和 $mAP@0.5:0.95$ 都明显高于基准模型。

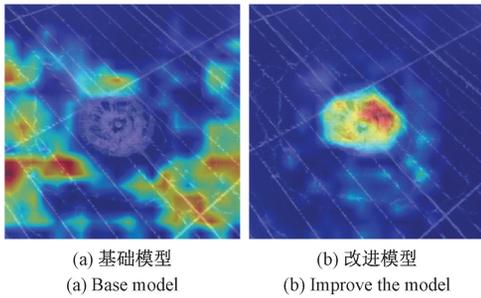


图 11 热力对比

Fig. 11 Comparison of thermograms

因此,相比于 YOLOv8n 基准模型,在进行光伏阵列表面缺陷检测时,改进后模型更易于部署在轻量化无人机设备中,且具有更高的测量精度。

3.5 对比实验

为了评估改进后模型的性能,设计了与其他主流的目标检测算法的对比实验。对比算法包括二阶段的

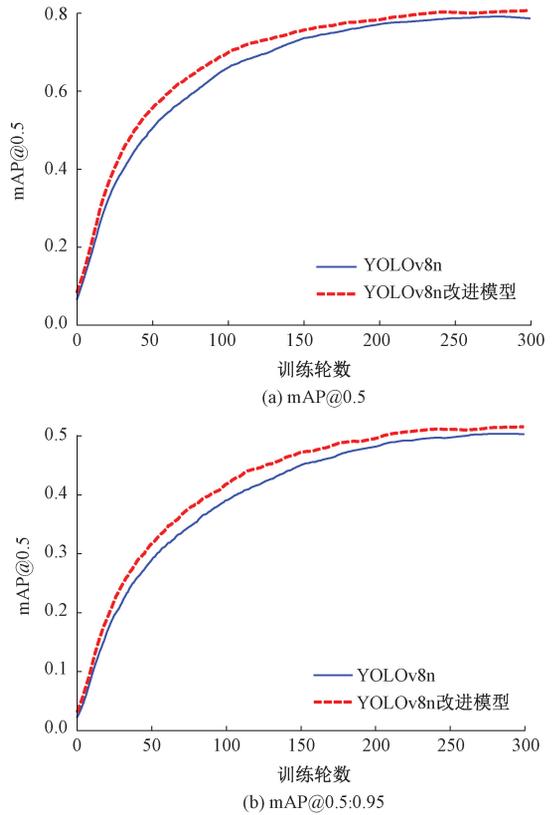


图 12 mAP 对比

Fig. 12 mAP comparison chart

Faster-RCNN 目标检测算法,一阶段的 SSD、YOLOv5n^[21]、YOLOv6s^[22]、YOLOv8n^[23]、YOLOv9t、YOLOv10n 和 YOLOv11n 目标检测算法。通过在相同的数据集上进行实验,且都已收敛的情况下,其实验结果如表 4 所示。

表 4 对比试验

Table 4 Comparative experiment

模型	P/%	R/%	$mAP@0.5$ /%	$mAP@0.5:0.95$ /%	Parameters/ $(\times 10^6)$	计算量 GFLOPS
Faster-RCNN	63.55	77.77	74.61	42.71	28.31	507.5
SSD	85.315	62.49	73.37	45.04	26.29	62.75
YOLOv5n	83.5	74.3	80	50.3	2.53	7.8
YOLOv6s	88.2	71.1	79.6	52.1	15.69	44.9
YOLOv8n	82.9	75.1	80.7	52.1	2.87	8.2
YOLOv9t	86	73.9	80.3	52.3	1.91	7.9
YOLOv10n	78	71.1	77.4	50.3	2.58	8.4
YOLOv11n	85.9	74	80.9	52	2.47	6.4
Ours	81.6	74.4	81.2	52.3	1.81	6

由表 4 可知,Faster-RCNN 和 SSD 在检测精度上相较于其他 6 种算法表现较差,同时它们的参数量和计算量过于庞大。在进行目标检测时,这些算法对计算资源的需求较高,且对设备的要求较严苛,不适合部署在轻量化

无人机设备上。而 YOLOv6s 算法虽然在某些方面有所改进,但其参数量和计算量相比其他 YOLO 系列算法仍然较大。YOLOv10n 算法的平均精度较低,不利于进行高精度的目标检测。而改进后模型,尽管在准确率和召

回率上略有下降,但其平均精度却优于 YOLOv8n,并且在参数量和计算量上大幅减少。与 YOLOv5n、YOLOv9t 和 YOLOv11n 算法相比,改进后模型在大多数指标上均表现出色,具有明显的优势。这充分证明了改进后模型在轻量化和检测精度方面优于其他模型,能够有效部署在轻量化无人机设备上,实现光伏阵列表面缺陷的实时检测。

3.6 光伏缺陷检测可视化分析

为了评估改进模型相较于原始 YOLOv8n 的性能,设计了可视化实验,实验结果如图 13 所示。从 YOLOv8n

与 YOLOv8n 改进模型检测结果的可视化图中可以看出, YOLOv8n 在检测过程中存在同一目标被多次检测的情况,导致了目标框的重叠。此外,还出现了目标框位置不准确、漏检和置信度较低等问题。改进后的算法在目标定位和目标识别方面明显优于原始的 YOLOv8n。有效减少了同一目标多次检测导致的目标框重叠现象,定位更加精确,漏检和误检的概率显著降低。在检测性能上,改进算法展现出了更强的优势,且具有更好的泛化性和鲁棒性。

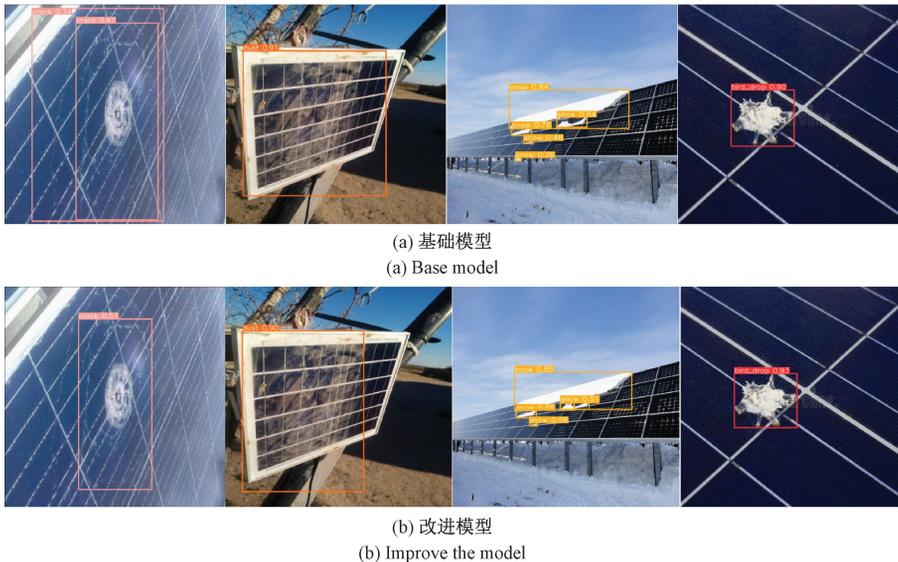


图 13 可视化实验对比

Fig. 13 Comparison of visualization experiments

4 结论

为解决光伏阵列表面缺陷检测时轻量化无人机对现有模型适配性差及检测精度不足的问题,基于 YOLOv8n 算法提出了一种兼具轻量化与高精度的改进模型。该模型融合了 CSPHet、PSA 注意力、CCFM 和 ACmix 模块。通过这些模块的协作用,减少了模型在特征提取时的冗余特征,增强了模型对全局和局部特征的建模能力,使其能够更有效地捕获全局信息与局部细节,并促进二者的深度融合,从而提高模型的计算效率和泛化能力。该优化策略不仅降低了模型的计算量和参数量,还进一步增强了特征提取和信息融合能力,使其更加适用于轻量化无人机部署,从而实现光伏阵列的表面缺陷的高精度检测。未来将进一步优化网络结构,以实现更高的轻量化程度和检测精度,使模型在工业场景中的轻量化部署和故障检测应用具备更高的适用性和实用价值。

参考文献

- [1] 许艺馨,周鹏,吴远丽,等. 碳达峰、碳中和背景下高职环保人才培养模式探究[J]. 环境教育, 2024 (12): 31-35.
XU Y X, ZHOU P, WU Y L, et al. Exploration of the cultivation mode of environmental protection talents in higher vocational education under the background of carbon peak and carbon neutrality [J]. Environmental Education, 2024, (12): 31-35.
- [2] 吕游,郑茜,齐欣宇,等. 基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 175-184.
LYU Y, ZHENG Q, QI X Y, et al. Research on infrared image photovoltaic module fault recognition based on improved EfficientNet [J]. Chinese Journal of Scientific Instrument, 2024, 45 (4): 175-184.
- [3] REN SH Q, HE K M, GIRSHICK R, et al. Faster RCNN: Towards real-time object detection with region

- proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(6): 1137-1149.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [J]. *ArXiv preprint arXiv: 1512.02325*, 2015.
- [5] 王鹏飞, 李海洋, 廖健标, 等. 基于改进 YOLOv5 的陶瓷基片缺陷识别 [J]. *国外电子测量技术*, 2024, 43(11): 187-196.
- WANG P F, LI H Y, LIAO J B, et al. Ceramic substrate defect recognition based on improved YOLOv5 [J]. *Foreign Electronic Measurement Technology*, 2024, 43 (11): 187-196.
- [6] 冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测 [J]. *光学学报*, 2018, 38(6): 250-258.
- FENG X Y, MEI W, HU D SH. Air target detection based on improved Faster R-CNN [J]. *Acta Optica Sinica*, 2018, 38 (6): 250-258.
- [7] 张琦, 胡广地, 李雨生, 等. 改进 Fast-RCNN 的双目视觉车辆检测方法 [J]. *应用光学*, 2018, 39(6): 832-838.
- ZHANG Q, HU G D, LI Y SH, et al. Improved Fast RCNN based binocular vision vehicle detection method [J]. *Journal of Applied Optics*, 2018, 39 (6): 832-838.
- [8] 唐聪, 凌永顺, 郑科栋, 等. 基于深度学习的多视窗 SSD 目标检测方法 [J]. *红外与激光工程*, 2018, 47(1): 302-310.
- TANG C, LING Y SH, ZHENG K D, et al. Multi window SSD object detection method based on deep learning [J]. *Infrared and Laser Engineering*, 2018, 47 (1): 302-310.
- [9] 郭建, 黄颖驹. 基于改进 YOLOv5 的光伏太阳能电池片缺陷检测 [J]. *组合机床与自动化加工技术*, 2024 (11): 104-109.
- GUO J, HUANG Y J. Defect detection of photovoltaic solar cells based on improved YOLOv5 [J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2024 (11): 104-109.
- [10] 赵会鹏, 曹景胜, 潘迪敬, 等. 改进 YOLOv8 算法的交通标志小目标检测 [J]. *现代电子技术*, 2024, 47(20): 141-147.
- ZHAO H P, CAO J SH, PAN D J, et al. Improved YOLOv8 algorithm for small object detection of traffic signs [J]. *Modern Electronics Technique*, 2024, 47(20): 141-147.
- [11] 胡彝. 基于深度学习的光伏板缺陷检测技术研究 [D]. 武汉: 湖北工业大学, 2021.
- HU B. Research on defect detection technology for photovoltaic panels based on deep learning [D]. Wuhan: Hubei University of Technology, 2021.
- [12] 徐威, 李为相, 方志, 等. 基于改进 YOLOv7-tiny 的光伏电池缺陷检测算法 [J]. *计算机工程与应用*, 2024, 60(15): 336-343.
- XU W, LI W X, FANG ZH, et al. Photovoltaic cell defect detection algorithm based on improved YOLOv7 tiny [J]. *Computer Engineering and Applications*, 2024, 60 (15): 336-343.
- [13] 吕禾丰, 陆华才. 基于 YOLOv5 算法的交通标志识别技术研究 [J]. *电子测量与仪器学报*, 2021, 35(10): 137-144.
- LYU H F, LU H C. Research on traffic sign recognition technology based on YOLOv5 algorithm [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(10): 137-144.
- [14] 石欣, 卢灏, 秦鹏杰, 等. 一种远距离行人小目标检测方法 [J]. *仪器仪表学报*, 2022, 43(5): 136-146.
- SHI X, LU H, QIN P J, et al. A method for detecting small pedestrian targets at long distances [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(5): 136-146.
- [15] 杨瑞君, 张浩, 叶璟. 改进 YOLOv8n 的轻量级遥感图像军用飞机检测算法 [J]. *电子测量技术*, 2025, 48(1): 154-165.
- YANG R J, ZHANG H, YE J. Improved YOLOv8n lightweight remote sensing image military aircraft detection algorithm [J]. *Electronic Measurement Technology*, 2025, 48 (1): 154-165.
- [16] 张志浩, 于长东, 刘百胜, 等. 基于双分支残差网络的粒子图像增强方法 [J]. *大连海事大学学报*, 2024, 50(4): 100-109.
- ZHANG ZH H, YU CH D, LIU B SH, et al. Particle image enhancement method based on double branch residual network [J]. *Journal of Dalian Maritime University*, 2024, 50 (4): 100-109.
- [17] SINGH P, VERMA V K, RAI P, et al. Hetconv: Heterogeneous kernel-based convolutions for deep cnns [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 4835-4844.
- [18] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. *Advances in Neural Information Processing Systems*, 2024, 37: 107984-108011.
- [19] ZHAO Y, LYU W, XU S, et al. Detsr beat yolos on real-time object detection [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern*

Recognition, 2024; 16965-16974.

- [20] PAN X, GE C, LU R, et al. On the integration of self-attention and convolution [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022; 815-825.
- [21] 赵鑫, 陈里里, 杨维川, 等. DY-YOLOv5:基于多重注意力机制的航拍图像目标检测[J]. 计算机工程与应用, 2024, 60(7): 183-191.
ZHAO X, CHEN L L, YANG W CH, et al. DY-YOLOv5:Aerial image object detection based on multiple attention mechanisms [J]. Computer Engineering and Applications, 2024, 60 (7): 183-191.
- [22] 孙旺, 付泽民, 赵志繁. 一种基于 YOLOv6n 的轻量化疲劳驾驶检测算法[J]. 汽车画刊, 2024 (2): 78-80.
SUN W, FU Z M, ZHAO ZH F. A lightweight fatigue driving detection algorithm based on YOLOv6n [J]. Auto Bild, 2024 (2): 78-80.
- [23] 朱圣博, 魏利胜, 高港, 等. 基于改进 YOLOv8s 的光学遥感小型船舶检测算法[J]. 电子测量与仪器学报, 2024, 38(10): 48-57.
ZHU SH B, WEI L SH, GAO G, et al. Optical remote sensing small ship detection algorithm based on improved YOLOv8s [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (10): 48-57.

作者简介



张彼德, 1996 年于河南科技大学获得学士学位, 1999 年于重庆大学获得硕士学位, 2002 年于重庆大学获得博士学位, 现为西华大学教授, 主要研究方向为电气设备在线监测及故障诊断、电力系统过电压分析及抑制等。

E-mail: fyhzxx2015@sina.com

Zhang Bide received his B. Sc. degree from Henan University of Science and Technology in 1996, M. Sc. degree from Chongqing University in 1999 and Ph. D. degree from Chongqing University in 2002, respectively. Now he is a professor in Xihua University. His main research interests include online monitoring and fault diagnosis of electrical equipment and overvoltage analysis and suppression of power system, etc.



王泽林 (通信作者), 2023 年于四川轻化工大学获得学士学位, 现为西华大学硕士研究生, 主要研究方向为光伏阵列的故障诊断。

E-mail: 976984532@qq.com

Wang Zelin (Corresponding author) received his B. Sc. degree from Sichuan University of Science & Engineering in 2023. Now he is a M. Sc. candidate at Xihua University. His main research interest includes fault diagnosis of photovoltaic arrays.