

DOI:10.19651/j.cnki.emt.2416847

基于重参数化的光伏电池缺陷检测算法^{*}

杨丽^{1,2} 邓靖威¹ 段海龙^{1,2} 杨晨晨¹ 李凤泉³

(1. 天津职业技术师范大学自动化与电气工程学院 天津 300222; 2. 天津职业技术师范大学天津市信息传感与智能控制重点实验室 天津 300222; 3. 天津经泓智能科技有限公司 天津 300222)

摘要: 针对光伏电池电致发光图像缺陷的复杂背景干扰不均、形状多变和缺陷多尺度等问题,提出了一种基于重参数化的光伏电池缺陷检测算法 OM-Detector。首先结合广义高效层聚合网络和在线重参数化,提出了OREPANCSPELAN4 模块,引入重参数化有效地通过梯度下降优化算法进行训练,在提升精度的同时降低了模型参数量,使模型轻量化;其次,在颈部网络中引入了多尺度卷积注意力模块,抑制复杂背景的干扰,提高模型检测细小缺陷的准确率;最后,结合重参数化特征提取—融合模块和多尺度卷积注意力模块,构建光伏电池缺陷检测器。使用光伏电池异常检测数据集对算法性能进行验证,实验结果表明,与 YOLOv8 检测网络相比,平均精度均值提升了 2.5%,参数量降低了 29%,推理速度加快了 5.7%,优于目前的主流目标检测算法,能快速、准确地对光伏电池表面缺陷进行检测。

关键词: 缺陷检测;重参数化;注意力机制

中图分类号: TN41 文献标识码: A 国家标准学科分类代码: 520.6040

Photovoltaic cell defect detection algorithm based on reparameterization

Yang Li^{1,2} Deng Jingwei¹ Duan Hailong^{1,2} Yang Chenchen¹ Li Fengquan³(1. School of Automation and Electrical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China;
2. Tianjin Key Laboratory of Information Sensing and Intelligent Control, Tianjin University of Technology and Education, Tianjin 300222, China; 3. Tianjin Jinghong Intelligent Technology Co., Ltd., Tianjin 300222, China)

Abstract: A defect detection algorithm OM-Detector based on reparameterization was proposed to solve the problems of uneven background interference, variable shape and multi-scale defects in electroluminescence image of photovoltaic cells. Firstly, OREPANCSPELAN4 module is proposed by combining generalized high-efficiency layer aggregation network and online reparameterization. The introduction of heavy parameterization can effectively train through gradient descent optimization algorithm, which can improve the accuracy and reduce the number of model parameters, making the model lightweight. Secondly, a multi-scale convolutional attention module is introduced into the neck network to suppress the interference of complex background and improve the accuracy of the model to detect fine defects. Finally, a defect detector is constructed by combining the heavy parametric feature extraction-fusion module and the multi-scale convolution attention module. The performance of the algorithm was verified by using the photovoltaic cell anomaly detection data set. The experimental results showed that compared with the YOLOv8 detection network, the mean average precision was increased by 2.5%, the number of parameters was reduced by 29%, and the reasoning speed was accelerated by 5.7%, which was superior to the current mainstream target detection algorithm and could detect the surface defects of photovoltaic cells quickly and accurately.

Keywords: defect detection; re-parameterization; attention mechanism

0 引言

由于光伏电池的缺陷会对发电效率造成严重的不良影

响,有缺陷的电池在放电过程中会产生大量的热量,可能引发火灾而导致财产损失和威胁到人们的人身安全^[1]。而且太阳能电池作为太阳辐射能转换为电能的核心部件,能量

收稿日期:2024-09-09

* 基金项目:天津市教委科研计划项目(2022ZD036)、天津市“揭榜挂帅”科技计划项目(2023JB02)资助

转换效率的高低和太阳能电池缺陷程度密切相关。因此,在光伏电池的制作过程中,需要对电池进行缺陷类型和位置的长期监控,以剔除缺陷电池并提高产品的合格率。随着深度学习的快速发展,基于计算机视觉的缺陷自动及时检测对避免缺陷光伏电池进入下一个生产环节起到了至关重要的作用。

传统的计算机视觉缺陷检测方法主要包括两个方面:基于滤波器的方法^[2]和基于手工特征的方法^[3]。滤波器的设计往往需要关于信号和噪声的先验知识,这些信息可能不完全或者难以准确获得,导致滤波效果不佳,而且参数通常是固定的,面对信号特性的变化无法自适应调整,导致性能下降。传统的特征提取方法主要依赖于人工设计的描述符,需要专业知识和复杂的参数调整,并且针对特定的应用,泛化能力和鲁棒性较差。

最近,深度学习模型在工业中获得了广泛的应用^[4-8]。深度学习是一种数据驱动的方法,它具有精度高、通用性广和可塑性强等优点。通过对大量样本进行学习,可以得到数据集的具体特征表示。深度学习模型具有更强的鲁棒性和泛化能力。Su等^[9]设计了一种新型的互补注意网络,并将这种新型的互补注意网络嵌入到Faster R-CNN(卷积神经网络)的区域建议网络中,该方法在太阳电池图像的缺陷分类和检测结果上都有明显提升,但是模型较大,消耗计算资源较多。伊力哈木·亚尔买买提等^[10]提出了一种改进的YOLOv4太阳能电池缺陷检测模型,该模型比原YOLOv4轻量化将近一倍,检测精度得到了提升,但总体来说检测精度略低。周启宸等^[11]提出了一种改进的YOLOv7太阳能电池缺陷检测算法,该算法在精度方面有所提升,但是牺牲了一些计算资源。唐政等^[12]提出了密集主干网络算法,对太阳能电池缺陷检测精度有明显的提升,但是网络模型较大。鲁东林等^[13]提出了一种改进的Faster R-CNN方法对太阳能电池缺陷进行检测,检测精度有较大的提升,但是模型较大,消耗计算资源较多。

尽管上述学者提出的网络对光伏电池特定缺陷识别效果良好,但由于光伏电池缺陷特征与背景相似度高,导致光伏电池细粒度缺陷特征提取不充分,检测网络模型规模一般较大,随着网络加深细小缺陷特征出现丢失的现象,从而使得对光伏电池的检测精度低,速度慢。RepNCSPELAN4模块^[14]有可能解决这些具有挑战性的问题,它融合跨级局部网络(cross stage partial network,CSPNet)^[15]和高效层聚合网络(efficient layer aggregation network,ELAN)^[16]网络,有利于最终模型的轻量化,但在轻量化的同时有可能导致精度的下降。针对上述问题,本文利用在线卷积重参数化(online reparameterization,OREPA)^[17]结合RepNCSPELAN4模块,提出了OREPANCSPLEAN4模块,通过梯度下降优化算法进行训练,保证了模型的轻量化和精度,在颈部网络中引入多尺度卷积注意力机制(multi-scale convolution attention,MSCA)^[18],捕获不同尺度的上

下文精细化信息,解决网络深化过程中细小特征消失的问题,进而提升模型的精度,最后提出一种光伏电池检测器OM-Detector,将OREPANCSPLEAN4模块和MSCA注意力模块嵌入到YOLOv8网络中,提高光伏电池图像中多尺度缺陷的检测效果。

1 OM-Detector 网络构建

光伏电池电致发光图像缺陷具有复杂背景干扰不匀、缺陷形状多变和缺陷多尺度等特点,随着网络的深化,这些缺陷容易被误认为是背景而跟背景一同消失,因此突出目标特征尤为重要。同时,为了确保光伏电池的生产效率,对光伏电池缺陷的实时检测也同样重要。本文在YOLOv8s的基础上对模型进行改进,提出OREPANCSPLEAN4模块和引入MSCA模块,构建光伏电池缺陷检测器OM-Detector。

1.1 RepNCSPELAN4 模块

RepNCSPELAN4模块是YOLOv9算法中的一个重要模块,它主要由可重参数化的CSPNet和ELAN组合而成。重参数化可将不可导的随机采样过程转换为可导的运算,从而使模型可微分,进而可以使用梯度下降等反向传播算法来训练模型,提高模型的性能和效率;CSPNet的一个重要应用是作为轻量级网络的主干网络,运用多种特征融合策略,如前期融合不同层次的特征图和最后融合不同层次的特征图,这些策略通过不同的方式处理特征图,影响梯度信息的重用和截断,从而影响网络的学习能力和计算效率,因此CSPNet不仅减少了计算量,而且在某些情况下还能提高模型的准确率。ELAN架构的一个显著特点是其结构中每个分支操作的输入通道和输出通道保持一致,只有最开始的两个 1×1 卷积操作有通道变化,这种设计方式有助于提高网络效率和性能。在RepNCSPELAN4模块中,通过结合CSPNet(图1(a))和ELAN(图1(b))这两种采用梯度路径规划设计的神经网络架构,设计了兼顾轻量级、推理速度和准确性的广义高效层聚合网络(generalized efficient layer aggregation network,GELAN),并通过重参数化,可以将不可导的操作转换为可导的等价形式,使得模型可以更有效地通过梯度下降优化算法进行训练,它的整体架构如图1(c)所示。在光伏电池缺陷检测当中,实时检测可以及时发现有缺陷的电池,提高光伏电池生产效率,该模块能够减少参数量,使得网络轻量化的同时保持了检测的精度,满足在光伏电池生产中缺陷检测的需求。

1.2 在线卷积重参数化

结构重参数化在计算机视觉任务中受到越来越多的关注,它在不引入任何推理时间成本的情况下提高深度模型的性能。多样分支块(diverse branch block,DBB)^[19]是借鉴Inception来实现结构重参数化的,将Inception的多分支、多尺度思想与重参数化思想进行结合,由于多分支结构类型更丰富(多尺度卷积、平均池化等),感受野更多样性,

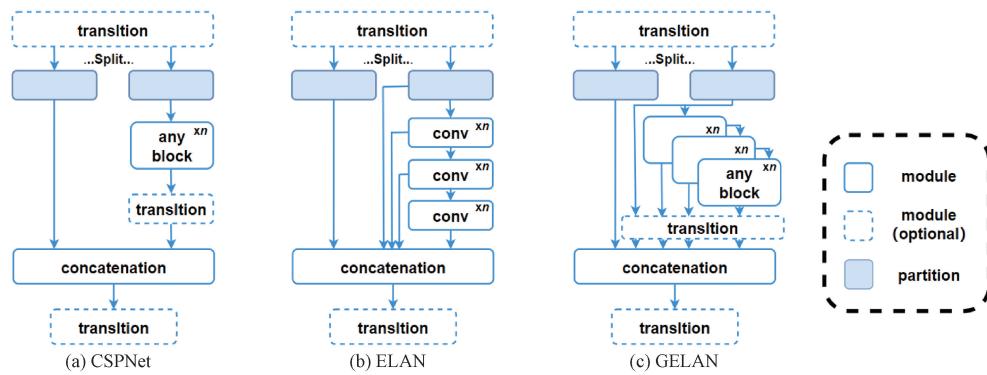


图 1 CSPNet、ELAN 和 GELAN 的结构图

Fig. 1 The structures of CSPNet, ELAN and GELAN

各操作具有不同的计算复杂度,因此更具有通用性,可以用来替换单个卷积进行训练。这种模型虽然在推理过程中效率很高,但为了达到较高的准确率,严重依赖于复杂的训练块,导致了大量的额外训练成本。OREPA 可以有效解决此问题,它通过引入一个线性缩放层来更好地优化训练块,通过将复杂的训练块压缩到单个卷积中来减少巨大的训练开销。OREPA 主要由两个阶段组成,在第一阶段(块线性化)中,删除原型参数块中的所有非线性组件,并引入了线性缩放层;在第二阶段(块压缩)中,将块合并到单个卷积层,如图 2 所示,通过这些步骤,在保持高性能的同时,显著降低了训练的成本。

在块线性化阶段中,去除所有非线性层,即重参数化块中的 BN 层。其次,为了保持优化的多样性,在每个分支的末端添加了一个缩放层,即归一化的线性替代。最后,为了稳定训练过程,在每个块之后添加了一个归一化层,如图 3 所示。接下来是将训练时的线性块压缩到单个卷积核中的过程。块压缩步骤将中间特征映射上的操作转换为更经济的内核操作,减少了在计算和内存方面重参数化的额外训练成本,如图 4 所示。将 OREPA 结合 RepNCSPELAN4 模块提出了 OREPANCSPLEAN4 模块,该模块可以使减少网络参数量,使网络轻量化,并提高了准确率。

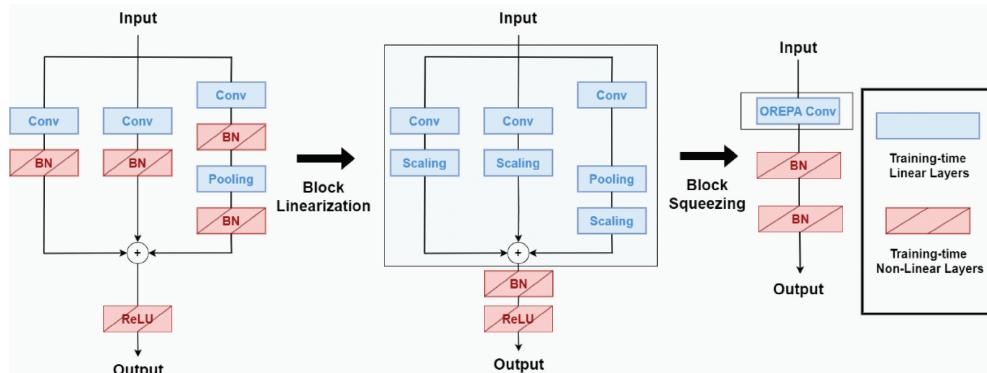


图 2 在线重参数化的过程图

Fig. 2 Process diagram for online reparameterisation

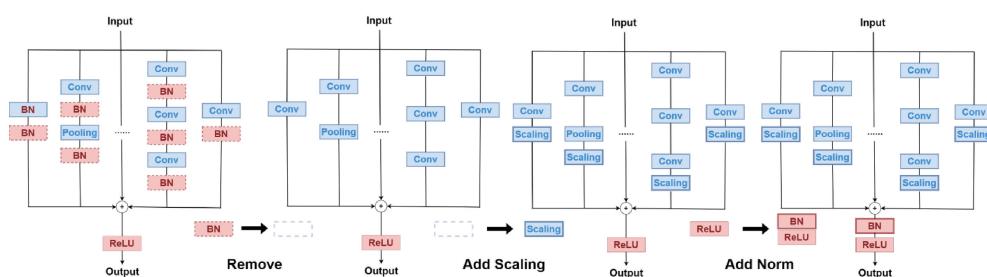


图 3 块线性化过程图

Fig. 3 Diagram of the block linearisation process

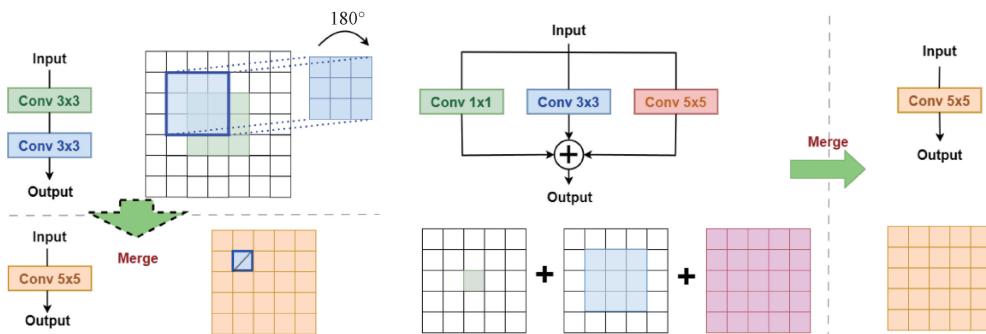


图4 块压缩过程图

Fig. 4 Block compression process diagram

1.3 注意力机制

注意机制是一种自适应选择的过程,其目的是使网络集中注意重要的部分。在光伏电池缺陷检测中,如裂痕缺陷最难被检测出来,裂痕具有细小、模糊等特征,且它与背景相似,容易被当成背景,另外随着网络的加深,细小特征容易消失,给光伏电池缺陷检测增加了难度。为了捕获多尺度上下文信息,将MSCA模块添加到颈部网络中,以便留住主干网络提取到的浅层细小特征。MSCA采用了类似于卷积神经网络的层次化设计,使得模型能够捕捉到不同尺度的上下文信息,它先运用卷积提取多尺度特征,然后利用提取到的多尺度特征作为注意权重来重新加权MSCA的输入。

MSCA包含用于聚合局部信息的深度卷积、用于捕获多尺度上下文的多分支深度卷积和用于模拟不同通道之间关系的 1×1 卷积3个部分,如图5所示。将 1×1 卷积的输出作为注意力权重,直接对MSCA的输入进行重加权。MSCA运算过程可以写成:

$$Att = Conv_{1 \times 1} \left(\sum_{i=0}^3 scale_i (DW - Conv(F)) \right) \quad (1)$$

$$Out = Att \otimes F \quad (2)$$

式中: F 表示输入特征, Att 和 Out 分别是注意映射和输出, \otimes 是元素矩阵的乘法运算, $DW-Conv$ 表示深度卷积, $scale_i$, $i \in \{0,1,2,3\}$ 表示第*i*个分支, $scale_0$ 表示shortcut分支,如图5所示。文献[20]提出,在每个分支中,使用两个深度条形卷积来近似具有大核的标准深度条形卷积,每个分支的内核大小分别设置为7、11和21。选择深度条形卷积的原因有两个,一是条卷积是轻量级的,为了模拟核大小为 7×7 的标准2D卷积,则只需要一对 7×1 和 1×7 的卷积,二是检测目标存在一些条状物体,如裂纹等。因此,条形卷积可以作为网格卷积的补充,有助于提取条形特征^[20-21]。

1.4 网络结构

本文提出一种基于YOLOv8的光伏电池缺陷检测器OM-Detector,结构如图6所示。

OM-Detector分别由输入端(Input)、骨干网络

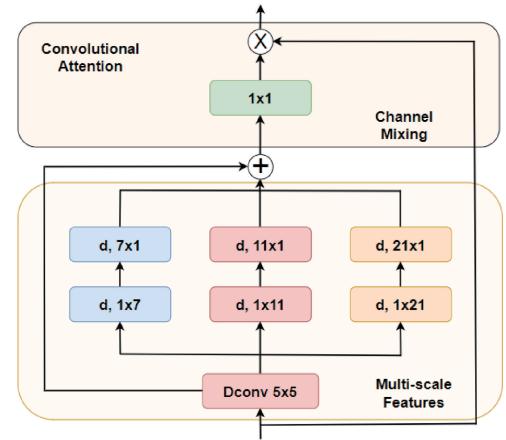


图5 MSCA结构图

Fig. 5 The structure of MSCA

(Backbone)、颈部网络(Neck)和检测头(Head)组成的。输入端负责把光伏电池的图片传入骨干网络、骨干网络负责从输入图像中提取光伏电池的缺陷特征,颈部用于融合骨干网络中提取的缺陷特征信息,最后由检测头对缺陷信息进行定位和分类。OM-Detector在YOLOv8的基础上融合OREPANCSPELAN4模块和MSCA模块。OREPANCSPELAN4模块兼顾轻量级、推理速度和准确性,在光伏电池缺陷检测中保证检测精度的同时加快了推理速度。但在背景干扰不均的情况下,对于裂缝等细长的缺陷不易被检测出来,因此在颈部网络中增加了MSCA注意力模块,模块中的深度条形卷积操作可以更好捕获从浅层中提取出来的细小条形特征,从而解决光伏电池中细小裂缝缺陷检测的难题。

2 实验及结果分析

为验证本文算法对光伏电池缺陷检测的性能,利用开源PVELAD数据集^[22]中对算法进行训练和测试。此外,本算法与其他主流检测算法进行了对比,验证了本文提出的算法对检测背景复杂的光伏电池缺陷表现出良好的性能。

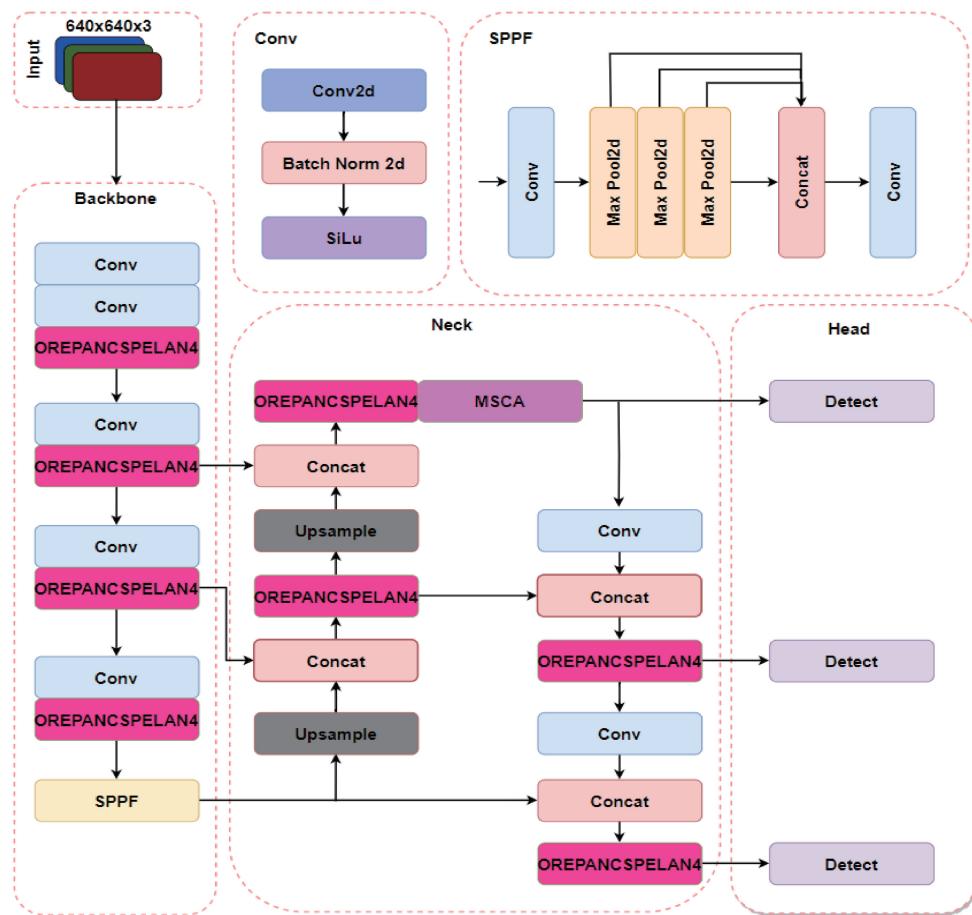


图 6 OM-Detector 结构

Fig. 6 The structure of OM-Detector

2.1 实验平台

本文使用的实验平台相关配置如表 1 所示。实验在 Windows10 操作系统上完成, 系统内存为 128 G, 采用 PyTorch 框架, 使用 CUDA 对算法进行加速。

表 1 实验配置

Table 1 Experimental configuration

实验设备	配置
CPU	Intel(R) Xeon(R) Gold 6248R
GPU	NVIDIA RTX3090
PyTorch	1.13.0
CUDA	11.7
CUDNN	8.6.0
Python	3.8

2.2 数据集与参数设置

本文使用河北工业大学和北京航空航天大学联合发布的 PVELAD 数据集, 经删除数据集中过少的类别后筛选出 6 936 张图像, 其中 4 500 张有缺陷图像和 2 436 张无

缺陷图像, 并按照图 7 (a)~(e) 的顺序将数据集分为 5 个类别, 分别是: 裂纹、断栅、星型裂缝、黑芯和短路, 如图 7 所示。在缺陷检测中, 当数量足够大时, 基本按照训练集、验证集与测试集的比例为 7:1:2 进行划分, 即训练集包含 4 855 张, 验证集包含 693 张, 测试集包含 1 388 张图像。

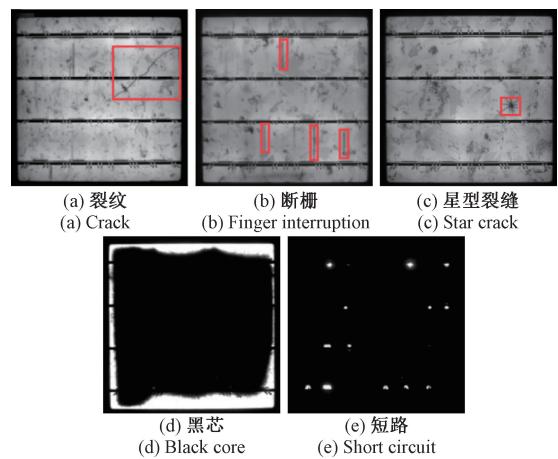


图 7 光伏电池各类别缺陷

Fig. 7 Photovoltaic cell defects by category

在训练 OM-Detector 网络模型过程中的超参数设置如表 2 所示。采用 Adamw 优化器,批量大小设置为 32,初始学习率设置为 0.01,最大训练轮次设置为 100,采用指数衰减的方法动态调整学习率,加快网络收敛的速度。

表 2 超参数设置

Table 2 Hyperparameter configuration

超参数	设定值
训练轮次	100
批量大小	32
图片大小	640×640
动量值	0.937
学习率	0.01
衰减率	0.0005

2.3 评价指标

为了对本文算法的分类和检测性能进行评估,采用精确度(precision, P)、召回率(recall, R)、平均精度均值(mean average precision, mAP)作为评估指标。计算公式如下:

$$AP = \int_0^1 P(x)dx, P = \frac{TP}{TP + FP} \quad (3)$$

$$AR = \int_0^1 R(x)dx, R = \frac{TP}{TP + FN} \quad (4)$$

$$mAP = \frac{1}{C} \sum_j AP_j \quad (5)$$

其中, TP 表示真实为正样本,检测为正样本; FP 表示真实为负样本,检测为正样本; FN 表示真实为正样本,检测为负样本; AP 表示某一缺陷的平均精度; AR 表示某一缺陷的平均召回率; mAP 表示总类别的平均精度; C 表示总类别数; j 表示类别。

2.4 算法对比实验

为了验证本文算法的有效性,用 YOLOv5s、YOLOv6s、YOLOv7-tiny、YOLOv8s 等主流算法与本文算法进行对比实验,采用 PVELAD 数据集进行检测效果和性能对比。为了确保实验的可比性,各对比算法均采用原始参数设置,并经过相同的训练流程,总共训练 100 轮,对所得模型进行定性和定量分析,以评估各个算法模型的性能。本文通过不同模型的检测效果来定性分析算法性能, YOLOv5s、YOLOv6s、YOLOv7-tiny、YOLOv8s 与本文所提算法检测效果如图 8 所示。

对于长裂痕, YOLOv7-tiny 检测能力最差, YOLOv6s 则多框重叠,非极大值抑制能力较差, YOLOv5s 则对长裂

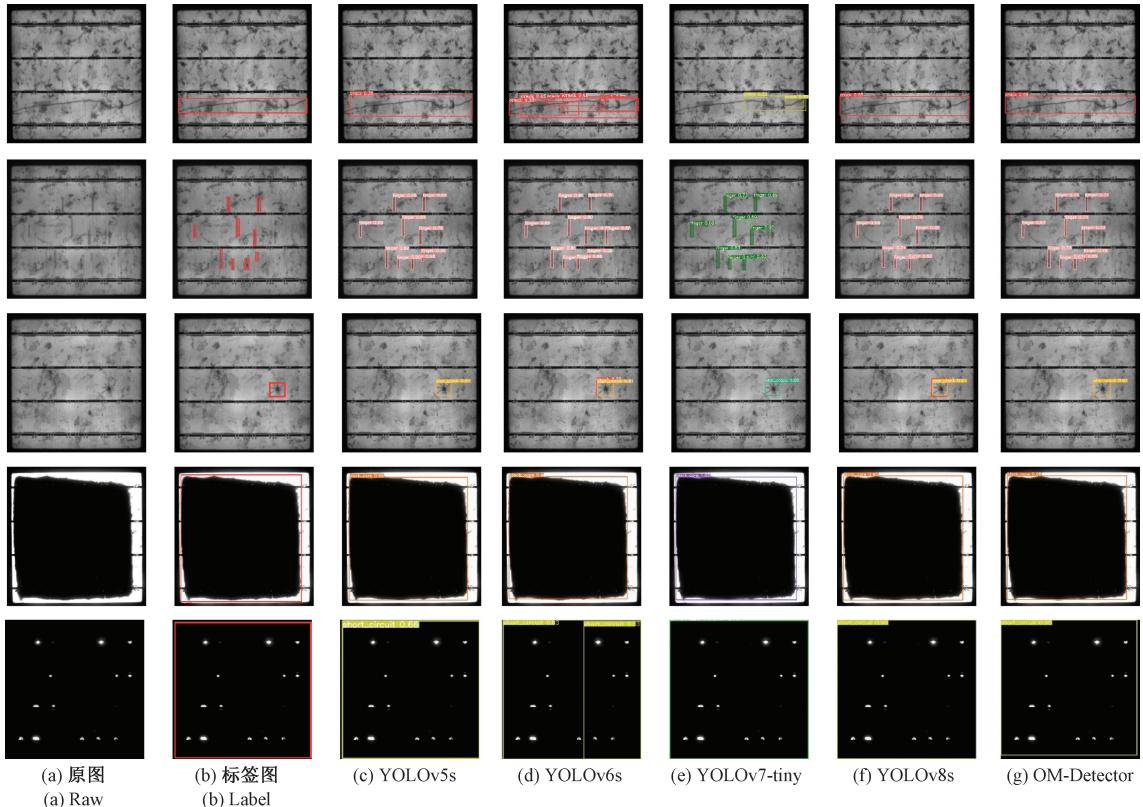


图 8 各种算法检测效果对比

Fig. 8 Comparison of detection effect of various algorithms

痕检测不完全,没有完全框出,本文算法在检测长裂痕时最准确,置信度最高;对于指缝,YOLOv7-tiny 和 YOLOv8s 出现漏检,YOLOv5s 对于指缝检测置信度最高,本文方法次之;对于星型裂缝,YOLOv7-tiny 达到了 1.00 的置信度,本文方法次之,YOLOv6s 和 YOLOv8s 出现检测为两个种类的情况,对星型裂缝的分类性能较差;对于黑芯和短路等大目标缺陷,YOLOv7-tiny 的检测置信度最高,本文方法略低于 YOLOv7-tiny,YOLOv5s 对于大目标缺陷的检测置信度最低;综上所属,OM-Detector 在 5 种缺陷类型检测中效果最佳,其他算法在某一类缺陷检测中均有不足。因此 OM-Detector 满足光伏电池缺陷的检测精度要求。

为了更好的验证本文所提算法的有效性,使用 PVELAD 数据测试集进行量化分析。不同算法的实验数据如表 3 所示,从参数量、检测速度、P、R 和 mAP 5 个方面进行比较,OM-Detector 参数量为 7.89 M,推理速度为 294 fps,P 为 91.2%,mAP 为 93.9%。在光伏电池缺陷检测性能方面,相对于 YOLOv5s、YOLOv6s、YOLOv7-tiny 和原

YOLOv8s 网络,mAP 分别提高了 4.0%、10.7%、7.0% 和 2.5%。在算法复杂度方面,参数量比 YOLOv5s 和 YOLOv7-tiny 略多,但在精度方面有较多提升,且比原 YOLOv8s 网络参数量降低了 29%。综合速度和精度评价,该算法均优于上述主流算法。在实际应用中,OM-Detector 的性能满足光伏电池缺陷实时检测需求。

2.5 消融实验

为了验证 OM-Detector 融合 OREPANCSPELAN4 模块和 MSCA 注意力模块的有效性,本文进行了消融实验,在采用相同的训练流程、超参数及环境的情况下、依次引入 RepNCSPELAN4 模块、OREPANCSPELAN4 模块和 MSCA 注意力模块,结果如表 4 所示。引入 RepNCSPELAN4 模块后,参数量明显降低,但 mAP 略有减少;在引入 OREPANCSPELAN4 模块后,参数量得到了保持,且 mAP 得到了提升;最后在颈部网络引入 MSCA 注意力模块,mAP 再次得到提升,达到了 93.9%,而参数量几乎没有不变。因此,OM-Detector 检测器较 YOLOv8s 在参数量降低的同时精度得到了提升。

表 3 各种算法结果对比

Table 3 Comparison of results of various algorithms

算法	准确率/%	召回率/%	mAP/%	参数量/M	推理速度/fps
YOLOv5s	86.2	85.4	89.9	7.00	175
YOLOv6s	84.8	82.6	83.2	16.30	258
YOLOv7-tiny	87.5	77.1	86.9	6.00	161
YOLOv8s	93.0	79.0	91.4	11.13	278
OM-Detector	91.2	88.2	93.9	7.89	294

表 4 消融实验

Table 4 Ablation experiments

方法	准确率	召回率	mAP	参数量/M
YOLOv8s	93.0	79.0	91.4	11.13
YOLOv8s+RepNCSPELAN4	87.0	87.6	90.5	7.86
YOLOv8s+OREPANCSPELAN4	88.6	87.2	92.4	7.86
YOLOv8s+OREPANCSPELAN4+MSCA	91.2	88.2	93.9	7.89

3 结论

本文提出一种基于在线卷积重参数化的光伏电池缺陷检测器 OM-Detector,在原 YOLOv8s 算法的基础上,融合重参数化的 OREPANCSPELAN4 模块和 MSCA 注意力机制,实现模型的轻量化,平衡检测速度和精度。为了验证本文所提 OM-Detector 的有效性,在开源数据集 PVELAD 上进行了训练和测试,OM-Detector 在准确率、召回率、mAP、参数量和推理速度等指标上分别达到了 91.2%、88.2%、93.9%、7.89 M 和 294 fps,并将 OM-Detector 与 YOLOv5s、YOLOv6s、YOLOv7-tiny 和

YOLOv8s 进行对比,验证了本文算法能有效检测复杂背景的光伏电池的缺陷以及细小缺陷,具有较高的检测准确率,模型复杂度满足实时应用要求,最后,将每一步的优化结果与原算法进行对比分析,优化后的算法优于原 YOLOv8s 算法。在后续工作中,将进一步丰富数据集,扩充缺陷的种类,提高多种类缺陷的检测精度和速度,实现部署应用。

参考文献

- [1] HERRAIZ Á H, MARUGÁN A P, MÁRQUEZ F P G. Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural

- network-based structure [J]. Renewable Energy, 2020, 153: 334-348.
- [2] LI X, LI F X. Adversarial examples detection in deep networks with convolutional filter statistics[C]. IEEE International Conference on Computer Vision, 2017: 5764-5772.
- [3] 包本刚.融合多特征的目标检测与跟踪方法[J].电子测量与仪器学报, 2019, 33(9): 93-99.
BAO B G. Target detection and tracking based on multi-feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (9): 93-99.
- [4] 高嘉, 刘涛, 王显峰, 等. TWRD-Net:一种用于曳引钢丝绳缺陷的实时检测网络算法[J]. 仪器仪表学报, 2023, 44(6): 223-235.
GAO J, LIU T, WANG X F, et al. TWRD-Net: A real-time detection network algorithm for traction wire rope defects [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 223-235.
- [5] 姜媛媛, 蔡梦南. 轻量化的印刷电路板缺陷检测网络 Multi-CR YOLO[J]. 电子测量与仪器学报, 2023, 37 (11): 217-224.
JIANG Y Y, CAI M N. Lightweight printed circuit board defect detection network Multi-CR YOLO[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(11): 217-224.
- [6] 史涛, 刘林, 朱文旭, 等. 基于改进 YOLOv5s 的车辆行人检测[J]. 国外电子测量技术, 2023, 42(12): 195-200.
SHI T, LIU L, ZHU W X, et al. Vehicle pedestrian detection based on improved YOLOv5s[J]. Foreign Electronic Measurement Technology, 2023, 42(12): 195-200.
- [7] 卢开喜, 段先华, 陶宇诚, 等. KThin-YOLOV7: 轻量级的焊接件表面缺陷检测[J]. 电子测量技术, 2024, 47(7): 9-18.
LU K X, DUAN X H, TAO Y CH, et al. KThin-YOLOV7: Lightweight inspection of surface defects on welded parts [J]. Electronic Measurement Technology, 2024, 47(7): 9-18.
- [8] 赵洋, 王军凯, 林志毅, 等. 基于改进 YOLOv8n 的钢材表面缺陷检测[J]. 电子测量技术, 2024, 47(13): 191-198.
ZHAO Y, WANG J K, LIN ZH Y, et al. Steel surface defect detection algorithm based on improved YOLOv8n[J]. Electronic Measurement Technology, 2024, 47(13): 191-198.
- [9] SU B Y, CHEN H Y, CHEN P, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network [J]. IEEE Transactions on Industrial Informatics, 2020, 17(6): 4084-4095.
- [10] 伊力哈木·亚尔买买提, 邓皓, 谢丽蓉. 基于改进 YOLOv4 的太阳能电池板缺陷检测[J]. 华南师范大学学报(自然科学版), 2023, 55(5): 21-30.
YILIHAMU Y, DENG H, XIE L R. Defect detection of solar panels based on improved YOLOv4 [J]. Journal of South China Normal University (Natural Science Edition), 2023, 55(5): 21-30.
- [11] 周启宸, 王伯超. 基于改进 YOLOv7 的太阳能电池片表面缺陷检测[J]. 计算机应用, 2023, 43 (S2): 223-228.
ZHOU Q CH, WANG B CH. Surface defect detection of solar cells based on improved YOLOv7[J]. Journal of Computer Applications, 2023, 43(S2): 223-228.
- [12] 唐政, 张会林, 马立新. 密集主干网络算法对太阳能电池的缺陷检测[J]. 激光与光电子学进展, 2023, 60 (14): 246-252.
TANG ZH, ZHANG H L, MA L X. Defect detection of solar cells by dense backbone network algorithm [J]. Advances in Laser and Optoelectronics, 2023, 60 (14): 246-252.
- [13] 鲁东林, 王淑青, 鲁濠, 等. 一种改进 Faster R-CNN 的太阳能电池片缺陷检测方法[J]. 激光杂志, 2022, 43(3): 50-55.
LU D L, WANG SH Q, LU H, et al. An improved defect detection method for solar cells based on Faster R-CNN[J]. Laser Journal, 2022, 43(3): 50-55.
- [14] WANG CH Y, YEH I H, LIAO H Y M. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision, Springer, Cham, 2025: 1-21.
- [15] WANG CH Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390-391.
- [16] WANG CH Y, LIAO H Y M, YEH I H. Designing network design strategies through gradient path analysis [J]. ArXiv preprint arXiv: 2211.04800, 2022.
- [17] HU M, FENG J Y, HUA J SH, et al. Online convolutional re-parameterization [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 568-577.
- [18] GUO M H, LU CH Z, HOU Q B, et al. Segnext: Rethinking convolutional attention design for semantic segmentation[J]. Advances in Neural Information

- Processing Systems, 2022, 35: 1140-1156.
- [19] DING X H, ZHANG X Y, HAN J G, et al. Diverse branch block: Building a convolution as an inception-like unit [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:10886-10895.
- [20] PENG CH, ZHANG X Y, YU G, et al. Large kernel matters-improve semantic segmentation by global convolutional network [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4353-4361.
- [21] HOU Q B, ZHANG L, CHENG M M, et al. Strip pooling: Rethinking spatial pooling for scene parsing [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 4003-4012.
- [22] SU B Y, ZHOU ZH, CHEN H Y. PVEL-AD: A large-scale open-world dataset for photovoltaic cell anomaly detection [J]. IEEE Transactions on Industrial Informatics, 2022, 19(1): 404-413.

作者简介

杨丽(通信作者),博士,副教授,主要研究方向为计算机视觉和机器人控制。

E-mail:yangli@tute.edu.cn

邓靖威,硕士研究生,主要研究方向为缺陷检测。

E-mail:16698508501@163.com