

文章编号 1004-924X(2024)14-2286-13

融合多尺度特征与注意力的太阳能电池 表面缺陷检测

周 颖^{1,2*}, 许士博¹, 陈海永^{1,2}, 刘 坤^{1,2}

(1. 河北工业大学 人工智能与数据科学学院, 天津 300130;

2. 河北省控制工程技术研究中心, 天津 300130)

摘要:为提高对太阳能电池电致发光(EL)成像各类表面缺陷的检测精度并降低漏检率,提出融合多尺度特征与注意力机制的太阳能电池表面缺陷检测算法 CMFAnet。首先,针对太阳能电池表面缺陷尺度跨度大的特点,设计了增强型多尺度特征融合方法,其基本单元由特征对齐模块和特征融合模块串联组成,对于不同语义级别的特征信息,特征对齐模块通过调整它们的尺度,使这些特征更容易融合在一起;其次,针对太阳能电池表面缺陷特征与背景特征相似程度高、几何形状多变的特点,设计了可形变幽灵卷积模块,其基本单元由可形变卷积、多路坐标注意力机制和幽灵卷积(Ghost conv)组成,多路坐标注意力机制优化了可形变卷积中 offset 的生成,幽灵卷积机制的引入则有效降低了网络模型的计算复杂度。实验结果表明,在光伏电池缺陷异常检测数据集 PVEL-AD 上,本文方法的平均检测精度(mAP)达 91.4%,相较于其他主流目标检测网络均有不同程度的提升。

关键词:多尺度特征;可形变卷积;坐标注意力;缺陷检测

中图分类号:TP391.41 **文献标识码:**A **doi:**10.37188/OPE.20243214.2286

Solar cell defect detection network combining multiscale feature and attention

ZHOU Ying^{1,2*}, XU Shibo¹, CHEN Haiyong^{1,2}, LIU Kun^{1,2}

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China;

2. China Hebei Control Engineering Research Center, Tianjin 300130, China)

* Corresponding author, E-mail: zhouying2007@163.com

Abstract: In order to improve the detection accuracy of various types of defects in the electroluminescence imaging of solar cells, a solar cell surface defect detection algorithm CMFAnet was proposed by fusing multiscale features and attention mechanism. Firstly, for the characteristics of solar cell surface defects with large scale span, an enhanced multi-scale feature fusion method was designed, whose basic unit consists of a feature alignment module and a feature fusion module connected in series, and for the feature information with different semantic levels, the feature alignment module adjusts their scales, so that these features can be fused together more easily; secondly, for the characteristics of solar cell surface defects with high level and variable geometry, a deformable ghost convolution module is designed. Secondly, for

收稿日期:2023-12-04;修订日期:2024-02-20.

基金项目:国家自然科学基金(No. U21A20482, No. 62173124)

the characteristics of high degree of similarity between defective features and background features on the solar cell surface and variable geometry, a deformable ghost convolution module was designed, whose basic unit consists of feasible variant convolution, multiplexed coordinate attention mechanism, and ghost convolution; the multiplexed coordinate attention mechanism optimizes the generation of offset in the feasible variant convolution, and the introduction of ghost convolution mechanism effectively reduces the FLOPs of the network model. The experimental results show that the mAP of this paper's method reaches 91.4% on the photovoltaic cell defect anomaly detection dataset PVEL-AD, which is improved to different degrees compared to other mainstream target detection networks.

Key words: multi-scale feature; deformable convolution; multi coordinate attention; defect detection

1 引 言

碳中和是应对全球气候变化的关键策略之一,旨在减少温室气体的排放并实现碳排放与吸收的平衡。太阳能作为一种新型的无污染可再生能源,是实现碳中和的有效手段。随着自动化生产线在制造业的大规模应用,太阳能电池板产量也随之高速增长。然而,自动化生产线会显著提高电池板的破损率,使其在生产过程中极易产生断栅、隐裂、粗线等缺陷。这些缺陷会影响电池板的转换效率和使用寿命。因此,太阳能电池板的缺陷检测非常关键。

近年来,随着信息化与工业化的融合与应用^[1],基于深度学习的计算机视觉技术已经成功应用于各种工业产品的表面缺陷检测,该技术的检测效率高、成本低,具有很大的发展前景^[2]。基于深度学习的太阳能电池 EL 检测技术已逐渐替代了传统的表面缺陷检测方法,EL 成像是一种利用材料在电场作用下呈现电致发光特性的热红外检测技术^[3]。通过红外相机或红外传感器,可以捕捉电池板表面的电致发光图像。这种图像能够提供高空间分辨率的图片,从而可以更好地识别太阳能电池中的微小缺陷^[4]。EL 检测由于操作快捷、可重复、成本低及无损测试等优点,已大规模应用于太阳能电池的表面缺陷检测。

文献[5]和文献[6]分别采用了不同的深度神经网络对太阳能电池表面缺陷进行检测,且均取得了较为可观的检测效果,但这两种方法对太阳能电池 EL 图像中的特征信息利用不够充分,还有较大的改进空间。不同尺度的特征层中包含了不同的细节、位置和语义等信息,文献[7]~文献[10]针对尺度跨度较大的目标,将多尺度特

征融合结构与注意力机制等引入到网络模型中,从而可以获得更丰富有效的特征信息,使网络对缺陷的识别更加精准。模型复杂度也是衡量模型优秀与否的标准之一,过于复杂的模型对于在功耗小、算力较低的设备上部署是不利的,为降低模型的部署难度,文献[11]通过引入幽灵卷积^[12]构建轻量化多尺度密集模块,有效地利用了浅层特征,同时提高了模型推理速度并减少参数量。文献[13]提出了一种多尺度视觉注意力网络,突出了目标区域特征并对杂乱的背景特征进行了有效地抑制。文献[14]针对表面缺陷类型多、形状复杂多变等特点,提出了一种基于可形变卷积^[15]的感兴趣区特征提取方法,提高了对具有复杂和不规则形状缺陷的检测性能。文献[16]将坐标注意力 CA^[17]应用在解码器中,从而使解码器的定位更加准确。在目标检测任务中,YOLO 系列框架^[18]均具有较快的检测速度和较高的检测精度,能够快速且准确地识别图像中的物体。

针对太阳能电池表面缺陷的特点,本文在综合考虑模型的跨尺度特征提取能力、对几何形状多变的表面缺陷识别能力和计算复杂度等问题后,提出融合多尺度特征与注意力的太阳能电池表面缺陷检测网络(Solar Cell Defect Detection Network Combining Multiscale feature and Attention, CMFAnet)。首先,为优化可形变卷积中 offset 的生成,设计多路坐标注意力机制(Multi Coordinate Attention, MCA)。然后,为降低模块的计算复杂度,提出将改进的可形变卷积与幽灵卷积相结合的卷积模块(Multi Coordinate Attention Deformable Ghost Conv Module, MCD)。最后,为增强模型的跨尺度特征提取能力,提出了

一种增强型多尺度特征融合结构。实验结果表明,CMFAnet在太阳能电池表面缺陷检测任务中有较好的性能。

2 检测网络CMFAnet

2.1 网络结构

本文所提出的基于改进YOLOv8n的CMFAnet检测网络如图1所示,它主要由Input, Backbone, Neck和Head四部分组成,Input部分用于图片输入,该部分利用Mosaic数据增强和自适应图像放缩扩大数据集,提高网络的鲁棒性。

Backbone部分用于对输入图片进行特征提取,传统的卷积操作采用固定的卷积核,在面对不规则目标时,有效特征的提取能力较弱,为提取到更有效的特征信息,在该部分引入基于多路坐标注意力与可变形卷积的MCD模块,以适应不同形状和尺寸的目标。Neck部分对来自Backbone的4个有效特征层进行特征融合,将低层特征的边缘、纹理等信息与高层特征的语义信息充分融合,加强网络对尺度变化较大目标的检测能力。Head为网络的分类器与回归器,为确保检测网络能够准确识别各类缺陷,采用解耦头结构,以加强对微小目标的检测能力。




图1 CMFAnet 结构图

Fig. 1 Architecture of CMFAnet

2.2 多路坐标注意力机制

太阳能电池 EL 成像包含丰富的通道信息和位置信息,并且不同的通道信息和位置信息分别发挥着不同的作用,为了使网络能够更全面地关注有效的敏感特征,提出多路坐标注意力机制

(MCA),该模块的结构图如图2所示。

MCA 模块与传统的坐标注意力(Coordinate Attention,CA)不同,MCA 模块首先对输入分别沿水平和垂直两个方向进行特征聚合,其次对特征聚合的结果在通道维度上进行堆叠,接着对堆




图 2 MCA 结构图

Fig. 2 Architecture diagram of MCA

叠之后得到的特征层进行卷积等操作,这样可以确保不同方向特征信息的充分交换,同时引入 Global Avgpool 操作,综合考虑全局的空间信息。MCA 模块不仅可以捕捉到跨通道的长程依赖信息,还可以提供关于方向和位置感知的信息,使网络能够更准确地定位和识别待检测目标。

对于输入 $x \in R^{C \times H \times W}$, MCA 模块分别使用大小为 $(1, 1)$, $(1, W)$ 和 $(H, 1)$ 的平均池化核对全局、水平方向和垂直方向上的每个通道进行编码。

全局平均池化后的第 C 维输出可以表示为:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x(i, j). \quad (1)$$

沿水平方向 ($X Avg Pool$) 的第 C 维输出可以表示为:

$$z_c^h(h) = \frac{1}{W} \sum_{j=1}^W x(h, j). \quad (2)$$

沿垂直方向 ($Y Avg Pool$) 的第 C 维输出可以表示为:

$$z_c^w(w) = \frac{1}{H} \sum_{i=1}^H x(i, w). \quad (3)$$

在得到水平与垂直两个方向上的输出后,对其进行特征聚合,生成一个中间特征图 l , 函数 l

可以表示为:

$$l = f([z^h, z^w]), \quad (4)$$

其中: $f(\cdot)$ 表示卷积、批归一化和 ReLU 激活函数操作, $[\cdot]$ 表示 Concat 操作。

然后再沿空间维度将 l 切分,得到新的水平方向和垂直方向的特征 l^h, l^w , 此时已进行了充分的信息交换。中间特征图 l 的权重可以表示为:

$$g = \sigma(f(l)), \quad (5)$$

其中: σ 表示 Sigmoid 激活函数, 水平方向和垂直方向的权重分别表示为 g^w, g^h 。MCA 模块的最终输出可以定义为:

$$y_c(i, j) = x_c(i, j) \times \sigma(l^h \times g^h) \times \sigma(l^w \times g^w) \times \sigma(f(z) \times \lambda(g)), \quad (6)$$

其中, λ 表示求平均。

2.3 可形变幽灵卷积模块

普通的卷积核采用固定的卷积核,在处理具有复杂背景纹理和不规则形状的太阳能电池表面缺陷时精度较低,虽然可以通过设计不同大小的卷积核以适应检测目标的几何变换,但是这会大大增加模型的参数量与计算复杂度。相比之下,可形变卷积可以将固定形状的卷积过程转化为可形变卷积,以适应物体的形状变换,从而更

容易在检测目标形状不规则的情况下提取到有效特征。因此,针对太阳能电池表面缺陷的特性,将所提 MCA 模块与可形变卷积和幽灵卷积相结合,构建可形变幽灵卷积模块(MCD),其中,幽灵卷积结构的引入可以有效地降低参数量与计算复杂度。MCD 模块结构图如图 4 所示。




图 3 MCD 结构图

Fig. 3 Architecture of MCD

传统的可形变卷积^[16]过程可表示为:

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n), \quad (7)$$

其中: p_0 代表输出特征图上的一个坐标点, p_n 代表卷积核中每一点相对感受野中每一点的偏移量, Δp_n 即偏移量 *offsets*, $y(p_0)$ 为可形变卷积的输出, $x(\cdot)$ 表示特征图 x 上 $(p_0 + p_n + \Delta p_n)$ 位置处的元素值, $w(p_n)$ 表示可形变卷积需要学习的卷积核权重, 该权重是由输入特征图经卷积操作生成的。本文所提出的 MCD 模块将该卷积操作替换为多路坐标注意力机制 MCA 来优化 *offsets* 的生成, 使其关注最优采样区。

MCD 模块的过程可表示如下:

对于给定输入特征 $x_{in} \in \mathbb{R}^{C \times H \times W}$, 首先使用卷积核大小为 1×1 的卷积提取特征, 获得通道数减半的浓缩特征:

$$x_1 = f_1(x_{in}), x_1 \in \mathbb{R}^{\frac{C}{2} \times H \times W}, \quad (8)$$

其中, f_1 表示卷积核为 1×1 的卷积、批归一化和 ReLU 激活函数。

Δp_n 即 *offsets* 的生成可以表示为:

$$\Delta p_n = f_{MCA}(x_1). \quad (9)$$

对 x_1 的进行可形变卷积操作后的输出可表示为:

$$x_2(p_0) = \sum_{p_n \in R} w(p_n) \cdot x_1(p_0 + p_n + \Delta p_n). \quad (10)$$

MCD 模块的最终输出可定义为:

$$y = [x_2(p_0), f_d(x_1)], \quad (11)$$

其中, $f_d(\cdot)$ 表示深度可分离卷积、批归一化和 ReLU 激活函数。

2.4 增强型多尺度特征融合结构

经过多次卷积之后, 网络的感受野会增加, 但同时会丢失部分边缘、纹理等细节信息, 为解决以上问题, 本文设计了浅层特征对齐与信息融合模块 (Low-Stage Feature Alignment and Information Fusion Module, LFAI-Module) 和高层特征对齐与信息融合模块 (High-Stage Feature Alignment and Information Fusion Module, HFAI-Module)。此网络模块可以提高检测网络对尺度跨越较大的表面缺陷的检测精度。




图 4 浅层特征对齐与信息融合模块

Fig. 4 Architecture of LFAI-Module

LFAI-Module 结构图如图 4 所示, 该模块对来自 Backbone 的特征层 B_i , ($i=2, 3, 4, 5$) 进行特征融合, 该过程可以表示为:

$$\begin{cases} L_1 = D(B_2) \\ L_2 = D(B_3) \\ L_3 = B_4 \\ L_4 = U(B_5) \end{cases}, \quad (12)$$

$$L_c = [L_1, L_2, L_3, L_4], \quad (13)$$

$$L_{out} = \delta(f_{cbs}(f_{mcd}(L_c))), \quad (14)$$

其中: $U(\cdot)$ 表示双线性插值上采样, $D(\cdot)$ 表示平均池化下采样, $[\cdot]$ 表示通道维度上的拼接, $\delta(\cdot)$ 表示分割, $f_{cbs}(\cdot)$ 表示卷积、批归一化和 SiLU 激活函数, $f_{mcd}(\cdot)$ 表示进行 MCD-Module 卷积操作。

HFAI-Module 结构图如图 5 所示, 该模块对进行过初步特征融合后的特征层 N_i , ($i=1, 2, 3$) 进行进一步的特征融合, 融合过程可表示如下:

$$\begin{cases} H_1 = D(N_1) \\ H_2 = D(N_2) \\ H_3 = N_3 \end{cases}, \quad (15)$$




图 5 高层特征对齐与信息融合模块

Fig. 5 Architecture of HFAI-Module

$$H_c = [H_1, H_2, H_3], \quad (16)$$

$$H_{out} = \delta(f_{obs}(f_{med}(H_c))). \quad (17)$$

3 实验及结果分析

3.1 实验环境与评价指标

本文的实验平台均为 Intel I5-12490F 和 NVIDIA GeForce RTX 3090, 开发环境为 Python3.7, 采用 PyTorch 框架构建。对模型进行训练时, 迭代轮数 epoch 设为 300 轮, 批大小 batch_size 设置为 16, 优化器使用随机梯度下降 (SGD), 动量 momentum 设置为 0.942, 权重衰减因子 weight_decay 设置为 0.000 5, 初始学习率 lr 为 0.000 1。

本文实验均采用准确率 (precision, P)、召回率 (Recall, R)、F 值 (F-measure, F)、平均精度 (Average Precision, AP) 和均值平均精度 (mean Average Precision, mAP) 作为网络模型的评价指标。

其中 P , R 和 F 被用来评价网络模型分类的性能, 其计算公式分别为:

$$R = \frac{TP}{TP + FN}, \quad (18)$$

$$P = \frac{TP}{TP + FP}, \quad (19)$$

$$F = \frac{2 \times P \times R}{P + R}, \quad (20)$$

其中: TP 表示将缺陷预测为缺陷的个数; FP 表示将无缺陷预测为缺陷的个数; FN 表示将缺陷预测为无缺陷的个数。

AP 和 mAP 被用来评价网络模型检测的性能, 其计算方法为:




首先, 根据模型的预测结果, 将样本按照置信度由高到低进行排序; 其次, 根据排序后的样本, 计算每个阈值下的精确率和召回率; 接着, 根据所有不同阈值下的精确率和召回率, 绘制出 P-R 曲线。P-R 曲线下的面积即 AP 值, mAP 则为多个类别 AP 值的平均值。

3.2 数据集

本文所使用的数据集为基于 EL 成像技术所构建的光伏电池缺陷异常检测数据集 PVEL-AD, 该数据集已公开。选取 PVEL-AD 数据集内较难检测的 4 类缺陷数据作为本文的数据集, 共计 4 578 张图片, 8 524 个缺陷标注框, 各类缺陷具体数量和示例如表 1 所示。

表 1 数据集详细信息

Tab. 1 Dataset details

类别	Crack	Finger	Thick_line	Star_crack
数量	2 262	2 672	2 173	1 462
示例				

3.3 CMFAnet 实验结果分析

本文所提出的融合多尺度特征与注意力的太阳能电池缺陷检测网络的实验结果如图 6~图 8 所示, 其中, 图 6 为混淆矩阵, 图 7 为 P-R 曲线, 图 8 为 F 值曲线, 从图中可以看出, 在针对太阳能电池表面缺陷检测的任务中,

相较于原始网络, CMFAnet 表现出更好的检测性能。

混淆矩阵可以较为清晰地展示分类结果的正确和错误情况, 是衡量分类模型性能的重要手段。混淆矩阵每一行代表一个真实目标类别, 每一列代表一个预测类别, 矩阵主对角线上




图6 混淆矩阵

Fig. 6 confusion matrix




图7 P-R曲线

Fig. 7 P-R curve

的元素则代表预测正确的样本占比。从图6中可以看出,相较于原始网络,CMFAnet在太阳能电池四类表面缺陷的检测任务中均有较好的表现。

P-R曲线下的面积代表每一类缺陷的检测精度AP,而AP值越高表示模型的效果越好。同时,从P-R曲线中可以看出,相较于原始网络,CMFAnet可以较好地兼顾精确率P和召回率R,证明CMFAnet有较好的检测性能。

F值是精确率P和R的调和平均值,它能够将准确率和召回率结合起来,从而更好地衡量模型在不同类别上的表现。F值在0~1之间,值越大代表模型效果越好。从图8中可以看出,CMFAnet表现出最优的检测性能。

CMFAnet与YOLOv8n的检测效果对比图如图9所示,从图中可以看出,CMFAnet的检测性能相较YOLOv8n,在提高各类缺陷检测精度的同时也减少了漏检现象的发生。




图 8 F 值曲线

Fig. 8 F-Measure curve




图 9 检测结果对比图

Fig. 9 Comparison of detection results

3.4 检测网络消融实验

为验证本文所提出模块的有效性以及相对于基准网络 YOLOv8n 的提升效果,设计由 MCD-Module 和特征融合模块的消融实验,如表 2 所示,表中的加黑项表示各项最优值,由表可以

看出 MCD 模块和增强型多尺度特征融合模块的加入使网络的检测性能分别提高 4.62% 和 2.58%,当两个模块同时作用于检测网络时,其检测精度提升至 91.40%,证明了本文所提模块的有效性。

表 2 CMFAnet 的消融实验
Tab. 2 Ablation experiments of CMFAnet

MCD	LFAI	HFAI	P	R	F	mAP	Params/M	Flops/G	FPS
—	—	—	87.79	65.76	74.53	83.75	3.16	8.86	114.5
✓	—	—	92.62	74.88	82.25	88.37	3.37	8.89	114.4
—	✓	—	86.67	75.24	80.55	85.42	3.41	8.9	110.5
—	—	✓	84.88	72.31	78.09	84.79	3.64	8.71	112.7
—	✓	✓	89.56	82.04	87.52	86.33	3.92	9.27	112.6
✓	✓	✓	88.12	85.41	86.73	91.40	6.36	11.9	106.3

3.5 注意力对比实验

为了验证本文所提出的 MCA 注意力的有效性,将 MCD-Module 中的 MCA 注意力分别替换为 SE, CBAM, CA, 同时加入一组不使用注意力机制的实验

作为基准实验,实验结果如表 3 所示,表中 AP_{cr} , AP_{fi} , AP_{sc} 和 AP_{tl} 分别表示 crack, finger, star_crack 和 thick_line 的 AP 值,由表中数据可知多路坐标注意力 MCA 相较于其他注意力均有不同程度的提升。

表 3 注意力对比实验
Tab. 3 Comparative experiments of different attention

方法	P	R	F	AP_{cr}	AP_{fi}	AP_{sc}	AP_{tl}	mAP	Params/M	Flops/G	FPS
v8n-MCD(w/o MCA)	86.84	69.42	76.75	77.98	92.48	88.60	84.14	85.80	3.21	8.86	118.1
v8n-MCD(SE)	90.75	67.90	77.00	75.61	93.68	92.46	84.30	86.51	3.96	8.91	109.8
v8n-MCD(CBAM)	90.05	71.23	79.25	75.55	94.25	92.57	84.44	86.70	4.83	9.04	103.2
v8n-MCD(CA)	92.08	69.51	78.51	76.28	93.94	96.20	81.85	87.07	3.52	8.97	112.6
v8n-MCD(MCA)	92.62	74.88	82.25	78.89	94.56	96.42	84.52	88.37	3.37	8.89	114.4

在目标检测任务中,热力图提供了检测目标的位置和置信度的可视化信息,热力图的中心聚集程度越高,表明模型的定位能力越好,图 10 展示了四类太阳能电池表面缺陷在不同注意力下的热力图对比。

从图中可以看出,在 MCA 注意力作用下, finger, thick_line 和 star_crack 这三类缺陷的热力图中心聚集程度相比其他注意力更高,且轮廓也最清晰。在 crack 缺陷中,同时包含了微小 crack 缺陷和大尺度 crack 缺陷,从图中可以看出,在 MCA 注意力的作用下,虽然大尺度 crack 缺陷的

中心聚集程度不是最高,但是其充分考虑了全局信息,能够在最大范围内定位大尺度缺陷,并且网络对微小 crack 的定位能力相比其他注意力更优,证明了本文所提 MCA 注意力的有效性。

3.6 特征融合模块对比实验

为了验证本文所提出的特征融合模块的有效性,将 YOLOv8n 中的特征融合模块分别替换为 PANet, BiFPN, AFPN 和 CCFM。实验结果如表 4 所示,由表中数据可知本文所提出的 LFAI 和 HFAI 模块相较于其他特征融合方法在检测性能上有一定程度的提升。




图 10 热力图对比

Fig. 10 Comparison of heat maps

表 4 特征融合模块对比实验

Tab. 4 Comparative experiments of different FPN

方法	P	R	F	AP _{cr}	AP _{fi}	AP _{sc}	AP _{il}	mAP	Params/M	Flops/G	FPS
v8n-PANet	86.24	63.11	72.88	78.48	91.73	84.94	72.17	81.83	3.15	8.86	114.5
v8n-BiFPN	88.57	52.94	66.27	71.28	92.14	78.83	76.43	79.67	3.14	7.41	131.2
v8n-AFPN	90.61	80.84	85.45	79.73	84.91	88.26	85.98	84.72	3.58	8.44	109.6
v8n-CCFM	85.95	73.51	79.24	77.59	89.42	83.47	83.44	83.48	3.21	6.7	127.4
v8n-LFAI&-HFAI	89.56	82.04	87.52	76.56	93.79	91.09	83.90	86.33	3.92	9.27	112.6

3.7 检测网络对比实验

为了验证CMFAnet在太阳能电池表面缺陷检测上的有效性与优越性,本文选取Faster R-CNN^[5],YOLOv5s^[6],YOLOv8n,Ghost-Net^[12],YOLOv7^[19],EfficientDet^[20]和SSD^[21]等检测网络行对比实验。

各网络在crack类别的检测效果如图11所示,从图中可以看出,相较其他网络,CMFAnet检测精度高、漏检现象少。

对比实验结果如表5所示。从表中数据可以看出,Faster R-cnn模型的准确率P较高,但F值较低,说明该模型无法在目标检测任务中的准确率和召回率之间取得平衡。CMFAnet的F值为86.73%,为本实验涉及的网络中最高值,F值越高则证明网络模型在目标检测任务中在精确率和召回率之间取得更好的平衡。CMFAnet在crack,star_crack和finger三类缺陷的检测精度均取得最优值,虽然thick_line的检测精度低于YO-

LOv7,但 CMFAnet 的参数量仅为 6.36M,并且 mAP 高达 91.4%,相较于基准网络 YOLOv8n 提

升了 7.65%,证明了本文所提网络 CMFAnet 在太阳能电池表面缺陷检测任务中具有较大优势。




图 11 crack 检测效果对比

Fig. 11 Comparison of crack detection results

表 5 网络模型对比实验

Tab. 5 Comparative experiments of different detection networks

方法	P	R	F	AP _{cr}	AP _{fi}	AP _{sc}	AP _{tl}	mAP	Params/M	Flops/G	FPS
SSD	93.02	34.02	45.75	65.12	74.81	92.66	63.99	74.14	26.29	62.75	49.5
Faster R-cnn	94.47	35.86	48.50	65.29	82.77	93.43	69.73	77.80	28.31	253.5	41.3
EfficientDet	89.74	40.57	53.01	70.46	86.38	94.56	71.29	80.67	15.7	8.4	68.6
YOLOv5s	91.26	61.95	72.51	71.48	92.74	93.25	73.39	82.71	7.28	17.16	62.3
GhostNet	91.55	59.32	71.25	68.69	92.51	83.34	79.13	80.92	5.37	1.52	70.8
YOLOv7	93.86	70.67	79.75	77.41	93.73	94.34	85.23	87.68	37.62	59.53	61.4
YOLOv7-tiny	94.42	38.66	51.25	71.06	85.00	93.43	69.81	79.87	6.07	13.32	82.1
YOLOv8n	87.79	65.76	74.53	77.68	92.63	86.59	78.11	83.75	3.16	8.86	114.5
CMFAnet	88.12	85.41	86.73	87.50	95.90	99.40	83.00	91.40	6.36	11.9	106.3

4 结 论

针对太阳能电池表面缺陷尺度跨度大、几何形状多变和背景纹理复杂的特点,本文提出一种融合多尺度特征与注意力的太阳能电池缺陷检测算法(CMFAnet),基于网络模型对比等实验证明了所提算法的有效性和优越性。

提出的多路坐标注意力MCA可以优化可形变卷积中 offset 的生成,使其更加关注最优采样区;提出的基于可形变卷积与多路坐标注意力的MCD模块可以增强网络的特征提取能力;提出的增强型多尺度特征融合结构可以更有效地对不同的特征层进行融合,提高了网络对目标的检

测能力。本文方法与 YOLOv8n 相比, crack, finger 和 star_crack 的检测精度分别提升了 9.82%, 3.72% 和 12.81%, mAP 提升了 7.65%, 同时也保持了较高的 FPS 值。实验结果充分表明了低层特征的边缘、纹理等信息和高层特征的语义信

息均有其不可替代的作用,也是目标检测模型要重点考虑的问题之一。今后将深入研究跨尺度融合与注意力机制在卷积神经网络中的应用,并进一步提高 crack 和 thick_line 这类尺度跨越较大的缺陷检测的准确率。

参考文献:

- [1] ZHENG X Q, ZHENG S, KONG Y G, *et al.* Recent advances in surface defect inspection of industrial products using deep learning techniques[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(1): 35-58.
- [2] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. *仪器仪表学报*, 2022, 43(1): 198-219.
ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(1): 198-219. (in Chinese)
- [3] 马桂艳, 张红妹, 史金超, 等. 基于电致发光的太阳能电池检测方法研究[J]. *光电子技术*, 2020, 40(3): 213-216.
MA G Y, ZHANG H M, SHI J C, *et al.* Study of electroluminescence imaging as a method to detect the defects of solar cells[J]. *Optoelectronic Technology*, 2020, 40(3): 213-216. (in Chinese)
- [4] 夏中高, 彭平, 景彦姣, 等. EL 检测 PERC 电池中间缺陷成因及改善方法的研究[J]. *太阳能学报*, 2023, 44(6): 198-203.
XIA Z G, PENG P, JING Y J, *et al.* Study on causes and improvement methods of intermediate defects in perc cells detected by el[J]. *Acta Energiæ Solaris Sinica*, 2023, 44(6): 198-203. (in Chinese)
- [5] 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*, 2021, 17(6): 4084-4095.
- [6] ZHANG M, YIN L J. Solar cell surface defect detection based on improved YOLO v5[J]. *IEEE Access*, 2022, 10: 80804-80815.
- [7] XU S W, QIAN H M, SHEN W Y, *et al.* Defect detection for PV Modules based on the improved YOLOv5s[C]. 2022 China Automation Congress (CAC). Xiamen, China. IEEE, 2022: 1431-1436.
- [8] 张大胜, 肖汉光, 文杰, 等. YOLOv5 上融合多特征的实时火焰检测方法[J]. *模式识别与人工智能*, 2022, 35(6): 548-561.
ZHANG D S, XIAO H G, WEN J, *et al.* Real-time fire detection method with multi-feature fusion on YOLOv5[J]. *Pattern Recognition and Artificial Intelligence*, 2022, 35(6): 548-561. (in Chinese)
- [9] 陈海永, 袁乐, 王世杰, 等. 基于多尺度编码互补注意力网络的光伏缺陷检测[J]. *太阳能学报*, 2023, 44(10): 191-197.
CHEN H Y, YUAN L /Y, WANG S J, *et al.* Photovoltaic defect detection based on multi-scale coding complementary attention network[J]. *Acta Energiæ Solaris Sinica*, 2023, 44(10): 191-197. (in Chinese)
- [10] ZENG N Y, WU P S, WANG Z D, *et al.* A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3507014.
- [11] 周涛, 杜玉虎, 石道宗, 等. 强化特征提取能力的下颌骨折检测 3M-YOLOv5 网络[J]. *光学精密工程*, 2023, 31(21): 3178-3191.
ZHOU T, DU Y H, SHI D Z, *et al.* Mandibular fracture detection with 3M-YOLOv5 network based on enhanced feature extraction capability[J]. *Opt. Precision Eng.*, 2023, 31(21): 3178-3191. (in Chinese)
- [12] HAN K, WANG Y H, TIAN Q, *et al.* GhostNet: more features from cheap operations [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 1577-1586.
- [13] WANG C, BAI X, WANG S, *et al.* Multiscale visual attention networks for object detection in VHR remote sensing images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 310-314.
- [14] WANG J L, XU C Q, YANG Z L, *et al.* De-

- formable convolutional networks for efficient mixed-type wafer defect pattern recognition [J]. *IEEE Transactions on Semiconductor Manufacturing*, 2020, 33(4): 587-596.
- [15] DAI J F, QI H Z, XIONG Y W, *et al.* Deformable convolutional networks[C]. 2017 *IEEE International Conference on Computer Vision (ICCV)*. Venice, Italy. IEEE, 2017: 764-773.
- [16] 刘彦磊, 李孟喆, 王宣宣. 轻量型YOLOv5s车载红外图像目标检测[J]. 中国光学(中英文), 2023(5): 1045-1055.
- LIU Y L, LI M Z, WANG X X. Lightweight YOLOv5s vehicle infrared image target detection[J]. *Chinese Optics*, 2023(5): 1045-1055. (in Chinese)
- [17] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Nashville, TN, USA. IEEE, 2021: 13708-13717.
- [18] TERVEN J, CORDOVA-ESPARZA D. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS [EB/OL]. 2023: *arXiv*: 2304.00501. <http://arxiv.org/abs/2304.00501>
- [19] 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(S02): 223-228.
- ZHOU Q C, WANG B C. Solar cell surface defect detection based on improved YOLOv7 [J]. *Journal of Computer Applications*, 2023, 43(S02): 223-228. (in Chinese)
- [20] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA. IEEE, 2020: 10778-10787.
- [21] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot MultiBox detector[M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.

作者简介:



周颖(1970—),女,河北安国人,博士,副教授,硕士生导师,主要从事图像处理 and 智能控制等方面的研究。E-mail:zhouying2007@163.com



许士博(1997—),男,河北石家庄人,硕士研究生,主要从事目标检测等方面的研究。E-mail:1265021108@qq.com