

基于改进 YOLOv5s 太阳能电池片表面缺陷检测算法

王 巍 余 欣 缪佳欣 刘晓宇

(四川大学机械工程学院 成都 610000)

摘 要: 太阳能电池片表面缺陷的出现会严重影响太阳能转化效率,准确检测太阳能电池片表面缺陷并及时处理可以有效提高发电效率。针对太阳能电池片生产过程中表面缺陷检测高精度、实时性的需求,本文提出了一种基于改进的 YOLOv5s 的太阳能电池片表面缺陷检测算法。该算法首先在主干特征提取网络中用 C3CA 模块替换网络中 C3 模块,并加入 CBAM 注意力机制,提升网络的特征提取能力;其次,在特征融合网络中引入 BiFPN 网络结构,提升网络中不同语义和尺度信息的特征融合能力;最后,在输出端引入解耦头,提高了模型网络的收敛速度与检测精度。实验结果表明:改进模型在光伏电池 EL 数据集上平均精度均值 $mAP@0.5:0.95$ 为 66.4%,相较于原网络提高了 7.1%,实现了对太阳能电池片表面缺陷的快速有效定位识别,在太阳能电池工业生产过程中具有一定的实际应用价值。

关键词: 太阳能电池片;YOLOv5s;缺陷检测;注意力机制;BiFPN

中图分类号: TP391.41;TM914.4;TN36 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Solar cells surface defect detection algorithm based on improved YOLOv5s

Wang Wei Yu Xin Miu Jiaxin Liu Xiaoyu

(School of Mechanical Engineer, Sichuan University, Chengdu 610000, China)

Abstract: The appearance of defects on the surface of solar cells will seriously affect the efficiency of solar energy conversion, accurate detection of defects on the surface of solar cells and timely treatment can effectively improve power generation efficiency. Aiming at the demand for high precision and real-time surface defect detection in the solar cell production process, this paper proposes a solar cell surface defect detection algorithm based on the improved YOLOv5s. The algorithm firstly replaces the C3 module in the network with a C3CA module in the backbone feature extraction network, and incorporates the CBAM attention mechanism to improve the feature extraction capability of the network; secondly, introduces the BiFPN network structure in the feature fusion network to improve the feature fusion capability of different semantic and scale information in the network; lastly, introduces a decoupled head in the output end, which improves the convergence speed of the modeled network with the detection accuracy. The experimental results show that the improved model has an average precision of 66.4% on the EL dataset of photovoltaic cells with an $mAP@0.5:0.95$, which is 7.1% higher than the original network. It realizes the fast and effective localization and identification of defects on the surface of solar cell wafers, which has certain practical application value in the industrial production process of solar cells.

Keywords: solar cell; YOLOv5s; defect detection; attention mechanism; BiFPN

0 引 言

近年来,由传统化石燃料大量消耗所导致的能源危机、气候变化以及环境污染等问题引起了人们的大量关注,推动发展清洁、环保的可再生能源成为了当下的热点话题。光伏发电技术作为当下新能源产业中相对成熟的技术,在推动能源结构转型的过程中起着至关重要的作用^[1]。太阳能电池片可以将太阳的辐射光转换为电能,是光伏发电系

统^[2]中的核心部分,其转换效率与使用寿命是影响光伏发电系统发电效率的重要因素。由于材料缺陷及制造工艺等因素的影响,太阳能电池片生产过程中可能会导致太阳能电池片表面出现缺陷,例如裂纹、断栅、划痕和破损等^[3]。目前常用的太阳能电池片表面缺陷检测方法是电致发光技术(electroluminescence, EL),其原理是通过在晶体硅太阳能电池上施加电压使其发光,利用 CCD 相机捕获图像并经由红外成像系统处理发送至计算机软件进行处理分析,用

以实现对太阳能电池片表面缺陷的检测与分析^[4]。

随着深度学习技术的发展与革新,基于深度学习的图像处理方法^[6]已逐渐成为当下的主流研究趋势,通过深度学习算法实现对太阳能电池片表面缺陷的识别与检测,相较于传统的图像处理算法具有检测精度高、检测速度快、高实时性等优点。张鹏飞等^[6]通过采用反向线性卷积与深度可分离卷积对主干网络进行优化,引入亚像素链接以及通道注意力引导模块优化了 YOLOv4 深度学习模型,实现了对太阳能电池片表面缺陷的快速精确检测。张德钰^[7]采用 CutMix 数据增强对 EL 图形进行处理,引入特征融合(feature fusion module, FFM)模块融合不同维度的特征并对图像背景进行抑制,模型的检测准确率 mAP50 提升到 87.7%。彭雪玲等^[8]提出了上下文转换网络(contextual transformer, CoT),引入 CBAM 注意力机制与上采样算子 CARAFE,使用 WIoU 作为边界框损失函数对 YOLOv5s 模型进行优化,提高了模型的检测精度。李婷等^[9]提出了一种改进轻量型 YOLOv5 的太阳能电池板缺陷检测方法,用 MobileOne 模块替换卷积模块,在主干网络添加深度可分离视觉转换(separable vision transformer, SepViT)模块,压缩了模型参数数量的同时提高了检测精度与检测速度。

上述研究工作为太阳能电池片表面缺陷检测算法研究提供了一定的指导,但当前基于深度学习的太阳能电池片表面缺陷检测算法仍存在计算复杂度高、耗时长以及检测缺陷种类较少等问题,在实际应用过程中仍存在一定的局限性。本文提出一种基于改进 YOLOv5s 的太阳能电池片表面缺陷检测算法,对原始网络模型进行了优化和改进,提高了模型在复杂场景下的泛化能力与鲁棒性,对太阳能电池片表面缺陷实现了快速、准确的识别,为工业检测提供了一种高效、精准、可靠的缺陷检测方法,对实际的工业生产具有一定的应用价值。

1 YOLOv5 算法概述

YOLOv5^[10]是一种单阶段目标检测算法,具有检测精度高,检测速度快等特点。YOLOv5 的网络结构由输入端(Input)、主干网络(Backbone)、颈部网络(Neck)、检测头(Head)四部分组成,根据网络模型的深度参数和宽度参数可以分为 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 四个版本。考虑到应用场景为工业用途,要求检测算法检测速度快、模型复杂度小,本文选择网络深度参数与网络宽度参数最小的 YOLOv5s 网络模型,其网络架构如图 1 所示。

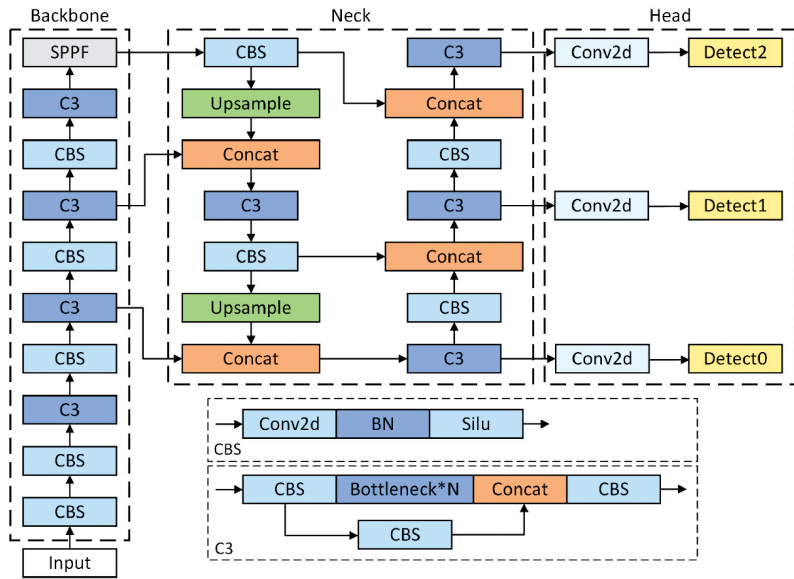


图 1 YOLOv5s 网络架构

Fig. 1 YOLOv5s network architecture

首先对输入端输入网络中的图像进行预先处理操作,采用了自适应图片缩放、自适应锚框计算、Mosaic 数据增强^[11]等预处理手段,以确保输入数据的一致性与网络训练的有效性。

主干网络的特征提取^[12]通过 CSPDarknet53 网络结构实现,该结构由复合卷积模块(CBS),集中-全面卷积模块(C3)、快速空间金字塔池化模块(spatial pyramid pooling

fast, SPPF) 3 个模块组成,通过堆叠模块实现网络结构的深化,进而实现对特征信息的提取。

颈部网络的特征融合通过特征金字塔网络(feature pyramid network, FPN)+路径聚合网络(path aggregation network, PAN)结构实现^[13],FPN 是一种自顶而下的特征金字塔结构,将高层特征图通过上采样与低层特征进行融合,使得低层特征图保留空间信息的同时具备较高的语义

信息;PAN 是一种自底而上的特征金字塔结构,对底层的特征图进行卷积操作与高层的特征图进行融合,使高层特征图在具备丰富语义信息的同时保留较好的空间信息。这种结构结合了 FPN 自上而下特征融合和 PAN 自下而上特征融合,实现了特征信息的充分融合与利用。

输出端检测头^[14]对颈部网络融合的 3 个尺度的特征图进行检测,预测图像中物体的类别和位置。通过 CIOU 函数^[15]、交叉熵损失函数来评估预测结果与实际标签的差异,并通过反向传播来更新优化网络模型参数。

2 改进算法介绍

基于 YOLOv5s 模型在太阳能电池片缺陷检测中的实际需求,对 YOLOv5s 模型进行参数优化和网络调整。如图 2 所示,在 YOLOv5s 的基础上,改进算法引入 C3CA 模块与 CBAM 注意力机制,增强主干网络特征提取能力;引入 BiFPN 加权双向特征金字塔网络,提升颈部网络特征融合能力;将检测头的回归与分类任务进行解耦,提升模型的泛化性能与检测精度。

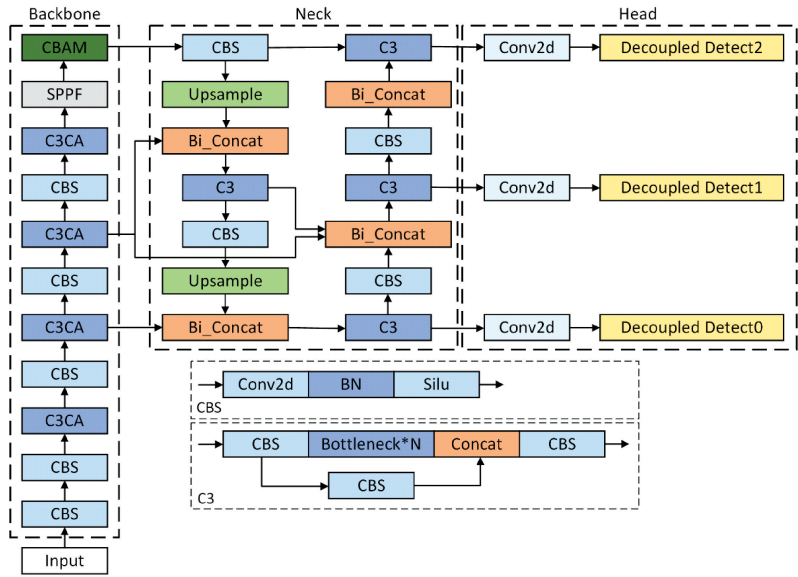


图 2 改进模型网络结构

Fig. 2 Improved model network structure

2.1 C3CA 模块

如图 3 所示,在原始模型中 C3 模块采用由 3 个卷积模块和 Bottleneck 结构组成,卷积操作增加了网络的深度和感受野,通过 Bottleneck 结构引入残差结构降低模型优化难度、促进模型训练并提高特征的表达能力。

CA)^[16]首先将输入特征图分为宽度和高度两个方向分别进行全局平均池化,分别获得在宽度和高度两个方向的特征图,公式为:

$$Z_c^h = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (1)$$

$$Z_c^w = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (2)$$

然后将获得全局感受野的宽度和高度两个方向的特征图拼接在一起,并送入 1×1 的卷积模块,将其维度降低为原来的 C/r ,然后将经过批量归一化处理的特征图 F_1 送入 Sigmoid 激活函数得到形如 $1 \times (W+H) \times C/r$ 的特征图 f ,公式为:

$$f = \delta(F_1([Z^h, Z^w])) \quad (3)$$

接着特征图 f 按原高度和宽度在 1×1 卷积核中进行卷积,分别得到通道数与原来一样的特征图 F_h 和 F_w 。经过 Sigmoid 激活函数后分别得到特征图在高度方向注意力权重 g^h 和宽度方向的注意力权重 g^w ,公式为:

$$g^h = \sigma(F_h(f^h)) \quad (4)$$

$$g^w = \sigma(F_w(f^w)) \quad (5)$$

最后在原始特征图上通过乘法加权计算,将得到最

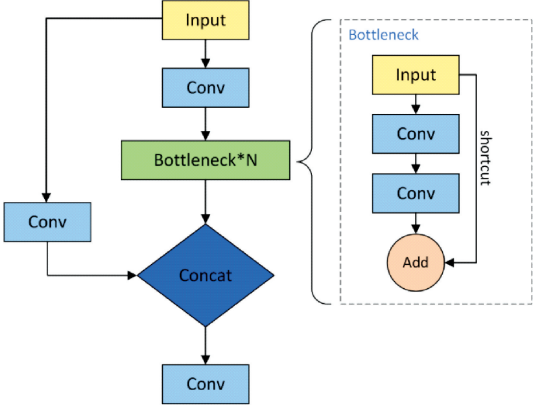


图 3 C3 模块结构

Fig. 3 Structure of C3 module

如图 4 所示,坐标注意力机制 (coordinate attention,

终在宽度和高度方向上带有注意力权重的特征图,公式为:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (6)$$

C3CA 模块在 C3 模块的基础上引入坐标注意力机

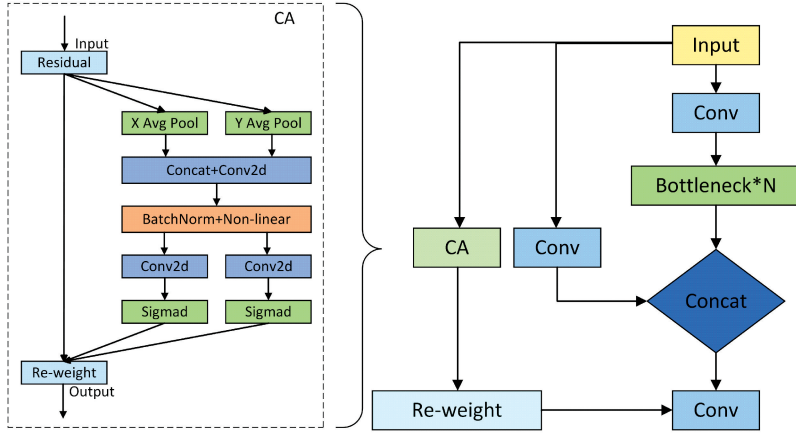


图 4 C3CA 模块结构

Fig. 4 Structure of C3CA module

2.2 BiFPN 加权双向特征金字塔网络

原始 YOLOv5 模型的特征融合网络为 FPN+PAN 结构,有效融合了不同尺度的特征信息与语义,但该结构存在只有一个输入边而没有进行特征融合的冗余节点,这些结点对特征融合贡献较小,增加了模型额外的参数量和计算量。

改进后的 YOLOv5s 算法采用 BiFPN^[17] 结构,如图 5 所示,该结构在自顶向下和自底向上路径之间建立双向连接,允许不同尺度特征间的信息更有效地流动和融合。BiFPN 结构中的双向连接有助于更好地在不同尺度上进行特征表示,提高了网络处理不同尺寸和复杂度对象的能

制,其结构如图 4 所示,C3CA 模块将卷积操作与注意力机制相结合,并行考虑通道维度与空间维度,将位置信息嵌入到通道注意中,用以增强移动网络学习特征的表达能力。

力,在提高模型效率和性能的同时没有明显提高模型的计算量。BiFPN 结构中删除了 PAN 结构中的冗余节点,采取对输入增加权重的方法来区分特征融合过程中不同特征的重要程度,从而提高多尺度目标特征的融合度。BiFPN 采用加权融合机制改进特征融合效果,为每个输入添加额外权重来调整不同输入对输出特征图的贡献,该融合将所有特征值的总和直接除以权重,计算公式为:

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} I_i \quad (7)$$

其中, I_i 为输入特征, O 为输出特征, ω_i 和 ω_j 为学习权重。




图 5 特征融合网络结构

Fig. 5 Structure of feature fusion network

2.3 CBAM 注意力机制模块

如图 6 所示, CBAM (convolutional block attention module) 注意力机制^[18] 是一种结合了通道注意力和空间注意力的注意力模块,通过关注输入数据中的重要特征来增强卷积神经网络的性能。CBAM 模块能够自适应地学习通道和空间维度的注意力权重,从而在不增加网络复杂性

的情况下提升模型的感知能力。

通道注意力(channel attention)如图 7 所示,用于增强神经网络在通道维度上的特征表示,通过学习每个通道的重要性权重,从而动态地调整不同通道的特征响应,以提高网络的表征能力。

空间注意力(spatial attention)如图 8 所示,用于增强




图 6 CBAM 注意力机制结构

Fig. 6 Structure of CBAM attention mechanism




图 7 通道注意力机制结构

Fig. 7 Structure of the channel attention mechanism




图 8 空间注意力机制结构

Fig. 8 Structure of the spatial attention mechanism

深度神经网络在空间维度上的特征表示,通过学习每个空间位置的重要性权重,从而动态地调整不同位置的特征响应,以提高网络的感知能力。

通道注意力和空间注意力机制的公式为:

$$Channel(X) = \sigma\left(\frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_{i,j}(X)\right) \quad (8)$$

$$Spatial(X) = \sigma(F_{avg}(X) \times F_{max}(X)) \quad (9)$$

式中: σ 表示激活函数, $F_{i,j}(X)$ 表示输入特征结构位置的特征。 $F_{avg}(X)$, $F_{max}(X)$ 分别表示输入特征图(X)经过全局平均池化和最大池化后的结果。

2.4 检测头的解耦

在 YOLOv5 传统模型网络中,检测头是耦合的,即分类任务与回归任务在同一个网络分支中同时进行的。这种设计在一定程度上简化了网络结构,由于分类任务更关注目标的纹理内容,而回归任务更关注目标的边缘信息,将两者耦合在一起可能会使得模型难以同时优化这两个任务,有可能导致任务间的相互干扰,影响检测性能。

为解决这一问题,本文在原始模型的基础上在检测头引入解耦头^[19](decoupled head),将原始的检测头替换为包含两个并行分支的解耦头,其中一个分支负责分类任务,另一个分支负责回归任务。每个分支包含多个卷积层和其他组件,以提取和处理特定于任务的特征。如图 9 所示,在原始检测头中检测头是耦合的,通道中包括置信度、类别、预测框坐标 3 类。而解耦头将以上 3 个预测任务分别进行预测,它包含一个 1×1 的卷积层来降低通道的尺寸,然后是两个平行的分支,分别由两个 3×3 的转换层来实现检测。解耦操作进一步提高了检测精度,加快了模型的训练速度,提升了模型的泛化性能。

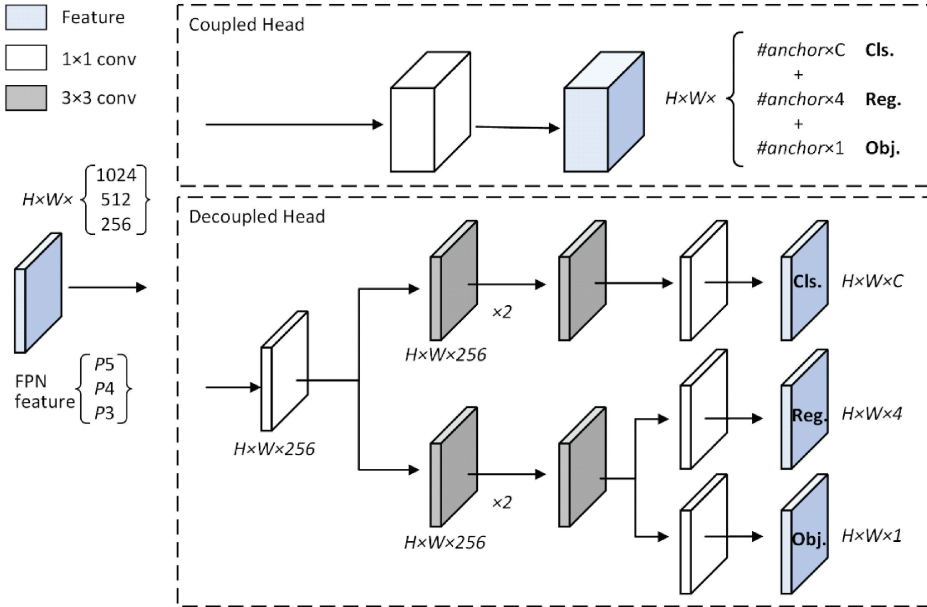


图 9 检测头结构

Fig. 9 Detection head structure

3 实验结果与分析

3.1 数据集介绍

本文使用由河北工业大学和北京航空大学联合发布

的开源工业数据集 PVEL-AD 进行模型的训练、验证以及测试。PVEL-AD 数据集包含 36 543 张具有各种内部缺陷和异构背景的近红外图像,图像分辨率为 $1\,024 \times$

1 024,数据集分为一类无异常数据和一类异常数据,其中异常数据分为 12 种缺陷类别,由于部分缺陷数据图像较少,本文对原始数据集中的图像进行筛选,选取线裂(crack)、断栅(finger)、黑芯(black_core)、粗线(thick_line)、星裂(star_crack)、短路(short_circuit)这 6 类缺陷共计 4 192 张图像进行训练和交叉验证。首先对组成的数据集进行图像预处理,再按照 8:1:1 的比例划分训练集、验证集、测试集。

3.2 实验环境及参数设置

本文所有实验的环境配置如表 1、2 所示。

表 1 实验环境配置表

Table 1 Configuration table for the experimental environment

名称	环境配置
操作系统	Ubuntu 20.04
GPU	NVIDIA GeForce RTX 4090
内存	60 G
Python	Python 3.8
深度学习框架	PyTorch 1.10.0

为了合理调用配置硬件资源,实验参数如表 2 所示。

表 2 部分实验参数配置表

Table 2 Configuration table of some experimental parameters

参数	数值
训练次数	300
批次训练数据量	24
动量因子	0.937
优化器	SGD
初始学习率	0.01
IoU 阈值	0.2

3.3 评价指标

为评估模型性能,本文选用的算法评价指标由精确度(Precision)、召回率(Recall)、检测平均精度均值 mAP,每秒传输帧数(fram per second, FPS)。其公式分别为:

$$Precision = \frac{TP}{TP + FP}$$
 (10)

其中,Precision 是指检测模型所检测出的正确物体占所有检测出的物体的比例,TP 表示检测到正确的样本数;FP 表示检测到错误的样本数。

$$Recall = \frac{TP}{TP + FN}$$
 (11)

其中,Recall 指的是真实物体被检测到的概率,FN 表示未检测出的样本数。

$$AP = \int_0^1 p(R) dR$$
 (12)

$$mAP = \frac{\sum_{i=1}^N AP}{N}$$
 (13)

其中,平均精度(AP)指在不同召回率下的平均精确度,N 表示种类总数。mAP@0.5 表示在 IoU 阈值为 0.5 时的平均精度均值,mAP@0.5:0.95 表示 IoU 阈值在 0.5~0.95 内,步长为 0.05 时的平均精度均值。

$$FPS = \frac{1\ 000\ ms}{Pre + I + NMS}$$
 (14)

其中:FPS 表示每秒传输帧数,即每秒内可以处理的图片数量,用来评估检测速度,FPS 值越高,模型检测速度越快。Pre(Pre-process)为图像预处理时间,I(Inference)为预处理后图像的推理时间,NMS 为非极大值抑制处理,即后处理时间,将推理后的图片进行处理输出。

3.4 消融实验

为了验证改进模型设计的合理性与有效性,本文将输入图像尺寸设置为 1 024×1 024,在原始 YOLOv5s 网络模型的基础上,分别引入 C3CA 模块、BiFPN 特征融合网络结构、CBAM 注意力机制和改进解耦头进行实验,通过消融实验验证不同改进方法对模型性能的影响。消融实验选择的评价指标为精确率 P、召回率 R、每秒传输帧数 FPS、平均精度均值 mAP@0.5 和 mAP@0.5:0.95,消融实验设计如表 3 所示。

表 3 改进算法的消融实验设计

Table 3 Design of ablation experiments with improved algorithm

模型	YOLOv5s	C3CA	BiFPN	CBAM	Decoupled Head
1	✓	—	—	—	—
2	✓	✓	—	—	—
3	✓	—	✓	—	—
4	✓	—	—	✓	—
5	✓	—	—	—	✓
6	✓	✓	✓	—	—
7	✓	✓	✓	✓	—
8	✓	✓	✓	✓	✓

如表 4 所示,本文消融实验将初始的 YOLOv5s 算法作为对照组实验,在特征提取网络中引入 C3CA 模块提升了模型对图片特征信息提取能力;将模型特征融合网络结构修改为 BiFPN 加权双向特征金字塔网络后,可以有效的将不同尺度特征图的语义信息与位置信息进行融合,提高模型检测性能;在模型的特征提取层引入 CBAM 注意力机制,使模型更高效的学习特征图中的信息来提高模型的检测精度;将模型检测头优化为解耦头后,可以更好的处理分类与回归任务,大大提高了模型的检测精度。

将本文提出的改进方法同时应用于 YOLOv5s 模型,精确率、召回率、平均精度 mAP@0.5 和 mAP@0.5:0.95 分别提升了 4.3%、1.2%、1.4%和 7.1%,检测精度达到了

表 4 改进算法的消融实验结果

Table 4 Results of ablation experiments with improved algorithm

模型	P/%	R/%	mAP@ 0.5/%	mAP@0.5: 0.95/%	FPS
1	80.1	88.2	88.0	59.3	106.4
2	77.3	89.9	88.6	60.7	91.7
3	80.6	87.7	88.0	59.7	104.2
4	80.2	89.0	89.5	64.4	105.3
5	84.3	84.7	88.4	63.6	75.2
6	79.3	90.6	88.8	61.4	89.3
7	89.2	84.6	90.1	65.6	91.7
8	84.4	89.4	89.4	66.4	65.8

最佳效果,同时每秒传输帧数 FPS 为 65.8,可以满足工业检测的速度需求。由此可知,本文提出的改进的检测模型能有效的提高 YOLOv5s 的检测精度,证实了改进方法的有效性。

如图 10 所示,图为改进模型和初始模型的平均精度均值 $mAP@0.5:0.95$ 数据对比,可见改进后的模型相对于初始模型收敛速度更为迅速,临近收敛点时震荡更小更为稳定,并且改进后的模型平均精度均值 $mAP@0.5:0.95$ 更高,在太阳能电池片表面缺陷检测时的检测精度更高、更具有优势。




图 10 $mAP@0.5:0.95$ 数据对比

Fig. 10 Data comparison of $mAP@0.5:0.95$

如图 11 所示,为改进模型和初始模型在太阳能电池片数据集中 6 类缺陷的检测平均精度均值 $mAP@0.5:0.95$ 结果对比。由图 11 可知各类缺陷检测精度均有明显提升,太阳能电池片表面缺陷特征较为复杂,容易与背景信息相互混淆影响模型检测精度,改进的网络结构使得模型能够更好的将缺陷的位置信息,通道信息和特征信息更好的融合,对模型的学习能力和检测精度有点明显提升。

为了更加直观地展示模型改进后的运行结果,本文在测试集中选取部分图片分别在初始模型和改进模型进行

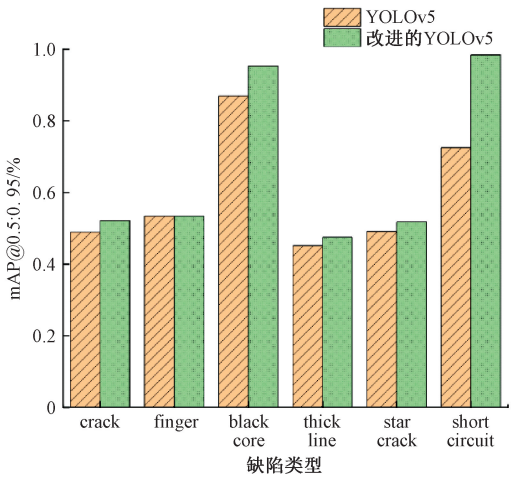



图 11 缺陷检测精度对比


Fig. 11 Comparison of defect detection accuracy

检测,对模型改进前后的效果进行比较,检测结果对比如图 12 所示。其中包括原始图像的缺陷位置和数量,原始模型对缺陷图像的检测效果和改进模型对缺陷图像的检测效果,测试实验分为 6 组进行。




(a) 缺陷重合时的漏检问题

(a) Missing detection problem when defects overlap




(b) 低亮度时的漏检问题

(b) Leakage problem at low brightness



(c) 小目标的漏检问题

(c) Leakage of small targets



(d) 缺陷重复检出问题

(d) Repeated detection of defects

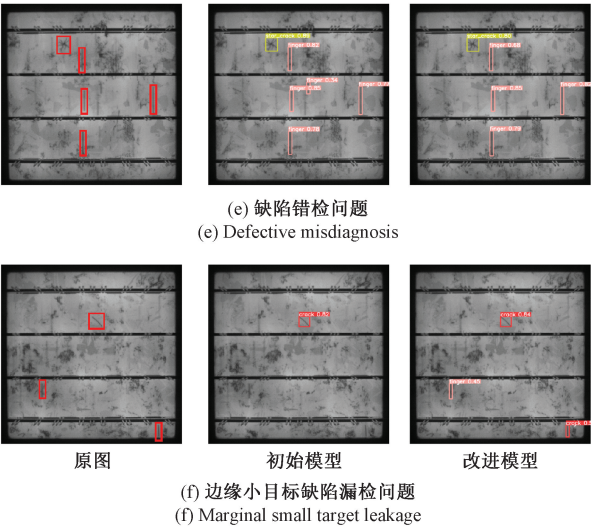


图 12 检测效果对比
Fig. 12 Comparison of detection effect

EL 图像背景信息较为复杂,具有大量非均匀的复杂纹理特征,在引入 C3CA 模块与 CBAM 注意力机制进行特征提取后,能够有效一直复杂背景对各缺陷特征的干扰,提高模型对有效特征的识别;在引入 BiFPN 网络结构后,可以有效抑制模糊背景的影响,促进不同尺度下的特征信息融合,提高模型对特征信息的提取能力;检测头的优化使得模型检测时的分类与回归的精度明显提高,增强了模型识别精度与泛化性能。

本文提出的改进 YOLOv5s 检测模型与初始模型相比,对缺陷的识别精度更高,降低了漏检率和误检率,改进的检测模型表现更为优异。

3.5 对比实验

除了与原始 YOLOv5s 网络模型对比,为了进一步验证本文提出的改进算法性能,将改进的 YOLOv5s 与 Faster R-CNN、EfficientDet、SSD、张德钰提出的 YOLOv5s-FFM 和彭雪玲提出的 YOLOv5s-CCCW 模型进行对比,并分析其结果。实验结果如表 5 所示。

表 5 不同算法性能对比

模型	主干网络	mAP50	FPS
Faster R-CNN	ResNet50	65.2	27.9
EfficientDet	Efficientnet-D1	74.3	18.2
SSD	VGG16	76.7	30.5
YOLOv5s	CSP-Darknet53	88.0	106.4
YOLOv5s-FFM	CSP-Darknet53	87.7	114.7
YOLOv5s-CCCW	CSP-Darknet53	86.5	74.6
本文模型	CSP-Darknet53	89.4	65.8

由实验结果可知,相比于对比试验模型本文改进模型

检测精度, mAP50 提升明显,可见本文改进模型对图像特征提取能力要优于其他模型;与 Faster R-CNN、EfficientDet、SSD 模型相比本文检测帧率分别提升了 37.9、47.6、35.3 帧;与 YOLOv5s、YOLOv5s-FFM、YOLOv5s-CCCW 模型相比本文检测帧率有所下降,对比表 4 推测可知,本文模型引入解耦检测头后,检测精度提升明显但是分离回归任务与分类任务增加了模型计算时间降低了模型的检测速度。

4 结 论

为提升太阳能电池在工业生产场景中的缺陷识别准确度,增强模型的可部署性,本文提出了一种基于改进 YOLOv5s 的太阳能电池片表面缺陷检测算法。检测算法在特征提取层引入 C3CA 模块与 CBAM 注意力机制提高网络特征提取能力,使用 BiFPN 加权双向特征金字塔网络提高网络对不同尺寸和复杂度对象的处理能力,采用解耦头提高了模型的检测精度。实验结果表明,相较于基准模型 YOLOv5s,改进模型的检测精度 mAP@0.5:0.95 提升 7.1%,检测速度为 65.8 fps,满足工业检测的速度要求,具有一定的工程实践应用价值,对其它太阳能电池片表面缺陷检测算法改进的研究工作也具有一定参考借鉴价值。

此外,检测模型性能提升受线裂、断栅、粗线和星裂几类缺陷影响明显,此类缺陷与背景相似度较高,模型难以区分缺陷与正常背景,未来的研究工作可进一步针对缺陷特点对模型进行更细化的改进,抑制背景的干扰,从而进一步提高模型的泛化能力;针对该算法在实际工业生产下的部署和应用,研究人员可通过模型剪枝等手段实现模型的轻量化处理以减少参数量与计算量,进一步提高检测速率,从而更好的匹配工业检测中的终端设备。

参考文献

[1] 王明泉. 新能源技术在能源发电中的应用研究[J]. 电力设备管理, 2024(15): 123-127.
WANG M Q. Research on the application of new energy technology in energy power generation[J]. Electric Power Equipment Management, 2024(15): 123-127.

[2] 王兆麟, 鲁宝春, 熊辉, 等. 光伏发电系统及其在电力系统稳定中的应用研究综述[J]. 黑龙江电力, 2016, 38(1): 89-94.
WANG ZH L, LU B CH, XIONG H, et al. Review of PV Generation System and its Application in Power System Stability [J]. Heilongjiang Electric Power, 2016, 38(1): 89-94.

[3] 刘玉淇, 吴一全. 基于机器视觉的太阳能电池片缺陷检测算法综述[J]. 光学精密工程, 2024, 32(6): 868-900.
LIU Y Q, WU Y Q. Review of defect detection algorithms for solar cells based on machine vision [J]. Optics and Precision Engineering, 2024, 32(6): 868-900.

- [4] 陈文志,张凤燕,张然,等. 基于电致发光成像的太阳能电池缺陷检测[J]. 发光学报, 2013, 34(8): 1028-1034.
CHEN W ZH, ZHANG F Y, ZHANG R, et al. Defect detection of solar cells based on electroluminescence imaging [J]. Chinese Journal of Luminescence, 2013, 34(8): 1028-1034.
- [5] HAZEM A M. Deep learning-based automated defect classification in electroluminescence images of solar panels[J]. Advanced Engineering Informatics, 2023, 58, DOI:10.1016/j.aei.2023.102147.
- [6] 张鹏飞,王淑青,黄剑锋,等. 基于机器视觉的太阳能电池片表面缺陷检测[J]. 组合机床与自动化加工技术, 2022(8): 144-147, 151.
ZHANG P F, WANG SH Q, HUANG J F, et al. Surface defect detection method of solar cell based on vision [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(8): 144-147, 151.
- [7] 张德钰. 基于 YOLOv5 的太阳能电池片 EL 图像缺陷检测算法[J]. 电视技术, 2024, 48(1): 42-47, 55.
ZHANG D Y. Solar cells el image defect detection and classification based on improved YOLOv5 [J]. Video Engineering, 2024, 48(1): 42-47, 55.
- [8] 彭雪玲,林珊玲,林志贤,等. 改进的 YOLOv5s 太阳能电池片缺陷检测算法[J]. 液晶与显示, 2024, 39(2): 237-247.
PENG X L, LIN SH L, LIN ZH X, et al. Defect detection algorithm of improved YOLOv5s solar cell [J]. Chinese Journal of Liquid Crystals and Displays, 2024, 39(2): 237-247.
- [9] 李婷,孙渊. 基于改进轻量型 YOLOv5 的太阳能电池板缺陷检测[J]. 组合机床与自动化加工技术, 2023 (11): 95-99, 106.
LI T, SUN Y. Defect detection of solar panels based on improved lightweight YOLOv5 [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2023(11): 95-99, 106.
- [10] 翁俊辉,成乐,黄曼莉,等. 基于 CS-YOLOv5s 的无人机航拍图像小目标检测[J]. 电子测量技术, 2024, 47 (7): 157-162.
WENG J H, CHENG L, HUANG M L, et al. Small target detection for UAV aerial images based on CS-YOLOv5s [J]. Electronic Measurement Technology, 2024, 47(7): 157-162.
- [11] XU B Y, YU S. Improving data augmentation for YOLOv5 using enhanced segment anything model [J]. Applied Sciences, 2024, 14(5), DOI:10.3390/app14051819.
- [12] JOOSHIN K H, NANGIR M, SEYEDARABI H. Inception-YOLO: Computational cost and accuracy improvement of the YOLOv5 model based on employing modified CSP, SPPF, and inception modules[J]. IET Image Processing, 2024, 18(8): 1985-1999.
- [13] LIN T, DOLLÁR P, GIRSHICK B R, et al. Feature pyramid networks for object detection[J]. IEEE Computer Society, 2017, DOI:10.1109/CVPR.2017.106.
- [14] RANJAI B, HEON J. YOLOv5 with ConvMixer prediction heads for precise object detection in drone imagery[J]. Sensors, 2022, 22(21): 8424.
- [15] ZHENG ZH H, WANG P, LIU W, et al. Distance-IoU Loss: Faster and better learning for bounding box regression [J]. AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [16] HOU Q B, ZHAO D Q, FENG J SH. Coordinate Attention for Efficient Mobile Network Design[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, 2021: 13708-13717.
- [17] TAN M X, PANG R M, VLE Q. EfficientDet: Scalable and efficient object detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision, 2018: 3-19.
- [19] GE ZH, LIU S T, WANG F, et al. YOLOx: Exceeding YOLO Series in 2021 [J]. ArXiv preprint arXiv: 2107.08430, 2021.

作者简介

王巍, 硕士研究生, 主要研究方向为图像处理、深度学习。
E-mail: 1425894981@qq.com

余欣, 硕士研究生, 主要研究方向为图像处理、深度学习。
E-mail: 2236438320@qq.com

缪佳欣, 硕士研究生, 主要研究方向为图像处理、深度学习。
E-mail: 752203007@qq.com

刘晓宇(通信作者), 博士, 副教授, 硕士研究生导师, 主要研究方向为测控技术与仪器、图像处理、深度学习。
E-mail: liuxiaoyu@scu.edu.cn