

DOI:10.19651/j.cnki.emt.2313181

基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测^{*}

张 猛 尹丽菊 周 辉 邹国锋 秦怡鸣 李铭宇

(山东理工大学电气与电子工程学院 淄博 255000)

摘要:针对太阳能电池图像背景复杂、缺陷形态多变及尺度差异大的特点,提出一种基于 SimAM-Ada YOLOv5 算法的太阳能电池缺陷检测方法。首先,将可变形卷积融入 CBL 模块,实现自适应学习特征尺度和感受野的大小;然后,将 Ada 池化融入 SPP 模块,增加缺陷信息的保留程度;最后,通过引入 SimAM 注意机制,进一步提高模型的特征提取能力。为了进一步优化改进 YOLOv5 算法,使用马赛克和 MixUp 融合数据增强、K-means++聚类锚盒算法、CIOU 损失函数以及 Hard-Swish 激活函数,以达到增强改进模型性能的目的。实验结果表明,改进 YOLOv5 算法在太阳能电池电致发光图像数据集的检测 mAP 达到 89.86%,相比于原始算法的 mAP 提高了 8.07%,速度达到 37.92 fps,在满足实时性的要求下可以更精准的完成太阳能电池缺陷检测任务。

关键词:深度学习;太阳能电池;YOLOv5;缺陷检测

中图分类号: TP391.4;TM914.4;TP183 文献标识码: A 国家标准学科分类代码: 470.40;520.20

Surface defect detection of solar cells based on SimAM-Ada YOLOv5

Zhang Meng Yin Liju Zhou Hui Zou Guofeng Qin Yiming Li Mingyu

(School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255000, China)

Abstract: In view of the complex background of solar cell image, changeable defect morphology and large scale difference, a method of solar cell defect detection based on SimAM-Ada Pool YOLOv5 algorithm was proposed. First, deformable convolution is incorporated into the CBL module to achieve adaptive learning of feature scales and perceptual field sizes; then, Ada Pool is incorporated into the SPP module to increase the degree of defect information retention; finally, the feature extraction capability of the model is further improved by introducing the SimAM attention mechanism. To further optimize and improve the YOLOv5 algorithm, the Mosaic and MixUp fusion data enhancement, K-means++ clustering anchor box algorithm, CIOU loss function, and Hard-Swish activation function are used to enhance the performance of the improved model. The experimental results show that the improved YOLOv5 algorithm achieves 89.86% detection mAP on the solar cell electroluminescence image dataset, which is 8.07% higher than the mAP of the original algorithm, with a speed of 37.92 fps, and can complete the solar cell defect detection task more accurately while meeting the real-time requirements.

Keywords: deep learning;solar cells;YOLOv5;defect detection

0 引言

现阶段受到环境污染和传统能源危机日趋凸显的双重压力,新能源得到井喷式发展^[1]。由于太阳能具有适用范围广、造价低、安全可靠等优点,成为现阶段高速发展的主流新能源之一。太阳能电池板是光伏发电的重要组件,硅晶体板脆弱易碎,容易在生产、安装、使用等环节因操作不

当产生缺陷^[2],这些缺陷不但会影响太阳能电池发电效率,还严重威胁着人们的生命财产安全^[3]。因此,太阳能电池缺陷检测方法的研究具有重要意义。

早期太阳能电池缺陷检测方法以人工目视检测为主,需要运维工程师携带仪器对太阳能电池进行逐个检查,这种检查方式工作量大、效率低,且过度依赖运维工程师的主观经验,检测精度无法得到保证。随后,基于手工特征提取

收稿日期:2023-03-23

*基金项目:国家自然科学基金(62101310)、山东省自然科学基金(ZR2020MF127)项目资助

和分类器的传统计算机视觉的方法得到广泛应用,该方法主要依据纹理、颜色、形状特征向量,采用分类器分类实现对缺陷的检测,可以实现无接触、较高准确度的检测,但是传统计算机视觉方法主要依赖于人工提取描述符,在使用过程中需要大量的参数调整,鲁棒性和泛化能力较差^[4-6]。

近年来,以卷积神经网络为代表的深度学习模型在目标检测、图像分类、语义分割等领域被广泛应用。相比于传统计算机视觉,深度学习通过学习大量的样本,获得数据集的具体特征表示,具有鲁棒性强、高精度、泛化能力好等优点。目前,基于深度学习的检测方法已经被许多学者应用在缺陷检测领域。2019年9月,Liu等^[7]提出一种基于改进Faster RCNN缺陷检测模型,通过将CNN与特征金字塔进行融合以及将RPN改进为GA-RPN的方法实现改进模型,该模型比原始模型的缺陷检测平均精度提高了11.26%;2021年11月,Li等^[8]提出一种特征融合、注意机制和VGG19主干网相融合的缺陷检测模型,实现利用小规模的太阳能电池数据集就可以有效实现模型的训练;2022年3月,鲁东林等^[9]将Faster RCNN算法中融入特征金字塔,并应用GA-RPN结构,实现检测效果有较大幅度的提高;2022年5月,王淑青等^[10]提出一种动态反馈的数据增强方法来提高检测精度,使用ELU作为激活函数,加快模型训练速度,并使用一种聚焦的高效交叉联合损失函数优化边界框损失,从而使改进YOLOv5检测模型检测精度提高,检测耗时下降。

在模型训练过程中,随着网络层数的增多和下采样,裂纹和断栅等微型缺陷的特征将很难被提取,使得缺陷检测效果差强人意。浅层特征映射包含局部信息,可以获得更多的微小缺陷特征、实现多尺度缺陷检测。注意机制可以有效选择或强调物体的微小特征,抑制图像中的噪声信息,适用于非均匀、复杂背景干扰下的太阳能电池图像缺陷检测。针对现阶段太阳能电池表面缺陷检测存在的问题,以及裂纹、断栅、实心黑3种不同特点的太阳能电池表面缺陷,提出一种改进YOLOv5的太阳能电池缺陷检测算法。在改进YOLOv5网络的设计中,将Ada池化融入SPP模块,提高网络的连通性,并且可以自适应地捕捉特征细节;然后,将可变形卷积引入CBL模块,实现对不同尺寸和形状的缺陷有效提取;并在Neck部分引入一个简单的、无参数的卷积神经网络注意力模块(a simple, parameter-free attention module for convolutional neural networks, SimAM)注意力机制,提高模型的特征提取能力。为了改进YOLOv5算法的性能得到更好的释放,改进算法使用马赛克和MixUp融合数据增强、K-means十聚类锚盒算法、CIoU损失函数以及Hard-Swish激活函数,以达到增强改进模型性能的目的。最后,通过消融实验、主流方法对比等实验客观评价改进模型的检测效果,结果表明改进模型在提高太阳能电池缺陷检测精度的同时保证了检测的实时性。

1 YOLOv5 基础模型

YOLO(you only look once)系列算法在科研工作者的不断研究下已经推出第5个版本YOLOv5。YOLOv5在目标检测中起着重要作用,具有收敛速度快、精度高、可塑性强的优点,还具有强大的实时处理能力和较低的硬件要求,可以移植到移动设备实时监测。YOLOv5模型有YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x四种不同型号,四种模型深度和宽度参数设置如表1所示,YOLOv5s是网络深度和宽度最小的模型,其他3种模型是在YOLOv5s的基础上不断深化和扩展的产品。

表1 4种不同型号 YOLOv5 模型深度和宽度参数设置

参数	YOLOv5s	YOLOv5m	YOLOv5l	YOLOv5x
深度值	0.33	0.67	1.00	1.33
宽度值	0.50	0.75	1.00	1.25

本文主要针对太阳能电池缺陷进行检测,为了在保证检测精度的同时满足模型轻量化和检测实时性的要求,经过实验验证,选择YOLOv5s作为基础模型性价比最高。YOLOv5s由输入端、骨干网、颈部、输出端四部分组成^[11],具体结构如图1所示。

1) 输入: 将输入图片缩放至网络设定尺寸 608×608 ,通过马赛克数据增强进行数据扩充,然后再进行归一化等操作;

2) 骨干网: 由1个Focus、4个CBL、3个CSP和1个SPP模块组成。通过引入FOCUS模块将3输出通道扩充至12输出通道,避免图片在采样过程信息丢失。通过引入CSP模块,避免检测模型出现梯度重复的问题。通过引入CSP模块,在保证检测精度的同时加快推理速度。通过引入SPP模块,提高特征点感受野、检测效果以及置信度;

3) 颈部: 位于主干网和输出层之间,使用特征金字塔结构(feature pyramid networks, FPN)的同时结合路径聚合网络(path aggregation network, PANet),促进不同网络层特征融合,提高检测模型的鲁棒性和检测性能;

4) 输出端: 采用并集上的广义交集(generalized intersection over union, GIOU)作为检测模型损失函数,输出3个不同尺寸的特征图对大、中、小3种目标进行预测。

2 改进 YOLOv5 算法网络结构

2.1 马赛克与 Mixup 融合数据扩充

深度学习需要经过大量的数据训练后才能获得数据集的具体特征表现,从而具有良好的性能。由于太阳能电站多分布于荒郊野外,地势偏远且环境恶劣,图像难以采集,数据扩充可以有效解决这一难题。数据扩充分为离线数据增强和在线数据增强两类,离线数据增强通过增强因子计算扩充大量数据,会占用较大的存储空间;在线数据增强是

在模型训练时在深度学习框架内进行数据增强,该方法以损耗极小的内存消耗为代价,获得大量的数据,可以有效提升网络的训练效果。

现阶段在机器学习中广泛使用在线数据增强进行数据扩充,其中马赛克数据增强和 Mixup 数据增强使用最为广泛。马赛克数据增强通过在数据集中随机选取 4 张图片进行裁剪、缩放操作后,再随机排列成一张图片;MixUp 增强

通过在数据集中随机选取两张图片进行加权求和,图片的标签也相应加权求和。改进 YOLOv5 检测模型将马赛克数据增强和 MixUp 数据增强方法相结合用于数据扩充,在训练过程中 50% 的概率使用马赛克数据增强,25% 的概率使用 MixUp 数据方法,且只在前 70% 的训练世代使用数据增强,在满足数据扩充的需求下有效降低数据增强对内存的损耗。

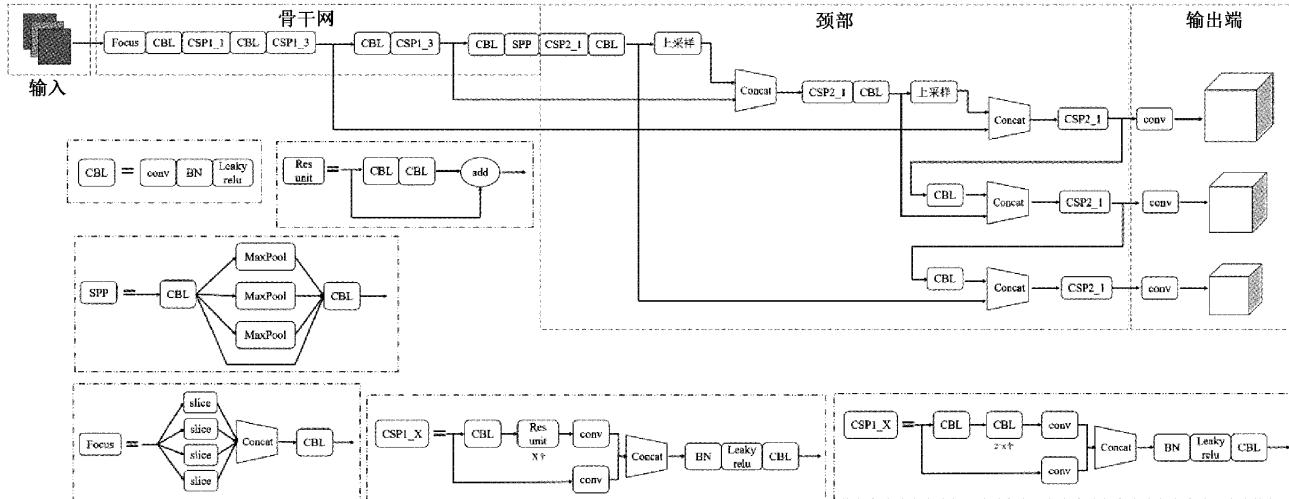


图 1 YOLOv5s 结构图

2.2 马赛克与 Mixup 融合数据扩充

1) 改进 SPP 模块

池化层可以增加卷积操作的感受野,同时使下采样生成的体积与输入体积相似,减少计算和内存的需求,从而可以创建层数更深的深层网络结构。目前大多数池化结构都融合了最大池化或平均池化的思想,虽然上述两种池化方法处理速度快、对内存的消耗少,但是它们在池化过程中对于重要信息的保留还有很大的进步空间。因此,Stergiou 等^[12]提出基于自适应指数平均 eDSC 池化和最大 eM 池化加权信息的 Ada 池化方法。

Ada 池化平滑逼近平均值($\tilde{\mathbf{a}}_{eDSC}$)和平滑逼近最大值($\tilde{\mathbf{a}}_{em}$)的加权组合公式为:

$$\tilde{\mathbf{a}}_{Ada} = \tilde{\mathbf{a}}_{eDSC} \cdot \beta + \tilde{\mathbf{a}}_{em} \cdot (1 - \beta) \quad (1)$$

$$\tilde{\mathbf{a}}_{eDSC} = \sum_{i \in R} \frac{e^{-\frac{w(\mathbf{a}_i, \mathbf{a}_{j_i})}{DSC}}}{\sum_{j \in R} e^{-\frac{w(\mathbf{a}_i, \mathbf{a}_{j_i})}{DSC}}} \cdot \mathbf{a}_i \quad (2)$$

$$\tilde{\mathbf{a}}_{em} = \sum_{i \in R} \frac{e^{\mathbf{a}_i}}{\sum_{j \in R} e^{\mathbf{a}_j}} \cdot \mathbf{a}_i \quad (3)$$

其中, $\tilde{\mathbf{a}}$ 表示池化输出, i 和 j 是区域 R 内坐标集合, $w(\cdot, \cdot)$ 是基于激活和平均激活之间距离的倒数, $\beta \in \{0, \dots, 1\}$ 是与 $\tilde{\mathbf{a}}$ 大小相同的权重矩阵。Ada 池化为每个内

核项计算梯度的特性,有效提高网络的连通性,自适应地捕捉特征细节。为了更好的保留缺陷特征信息,提高模型的检测精度,改进 YOLOv5s 在 SPP 模块引入 Ada 池化,具体结构如图 2 所示。

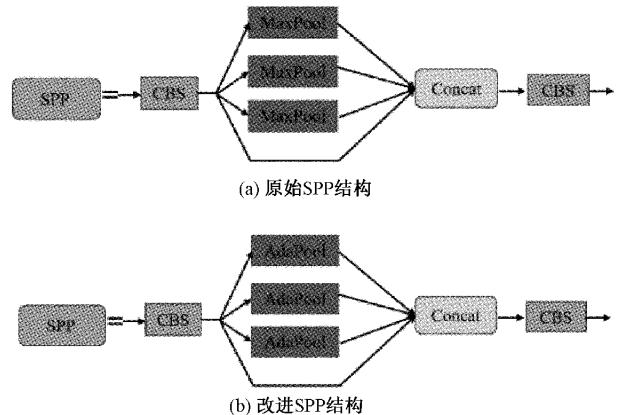


图 2 引入 Ada 池化前后 SPP 结构示意图

图 3 为不同池化方法处理效果对比图。相比图 3(b)最大池化和图 3(c)平均池化两种常用池化方法的处理效果,图 3(d)Ada 池化根据核区域的相关性确定其权重,不受相邻核项的影响,从而实现相邻区域区分度的增强,保留更多的重要特征信息,促进模型检测精度的提高。

2) 可变形卷积

YOLOv5 检测模型使用固定矩形结构的标准卷积对输入特征图的固定位置进行采样,特征点的感受野是固定

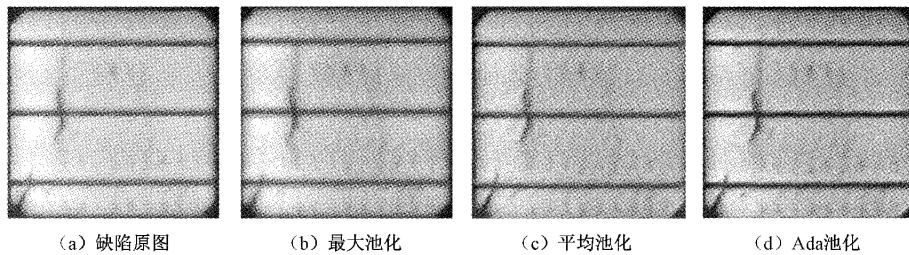
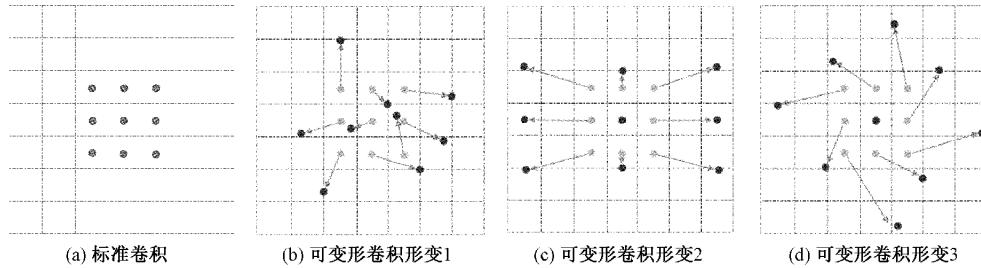


图 3 不同池化方法处理效果对比图

的,无法有效提取特征图中不同位置对应的不同尺度和形状的目标。通过引入可变形卷积^[13]可以有效克服固定矩形结构采样的缺点,实现对尺度和感受野大小得自适应学习。

可变形卷积通过平行卷积层从前面的特征映射中学习偏移量,卷积核的采样点发生偏移进而采样网络自由形变,

实现采样点集中在感兴趣的目标或者区域。图 4 为常规卷积和可变形卷积采样位置示意图,从图 4(a)可以清楚看出标准卷积只具有固定矩形结构的采样网络,图 4(b)~(d)每个卷积核的采样点都增加了偏移量,可以在周围任意采样,突破了标准卷积的局限性。

图 4 3×3 标准卷积和可变形卷积示意图

在可变形卷积的操作中,利用规则网络对输入特征图 F 进行卷积采样,采样位置集合 V 通过 Δp_n 来实现采样位置的偏移,同时对每个采样点预测一个权重 Δm_n ,其中 N 为网格中像素个数,输出特征图上的每个位置 p_o 的输出值 $y(p_o)$ 为:

$$y(p_o) = \sum_{p_n \in R} w(p_n) \cdot x(p_o + p_n + \Delta p_n) \cdot \Delta m_n \quad (4)$$

$$\Delta p_n = 1, 2, \dots, N \quad (5)$$

采样点是在偏移后的 $p_n + \Delta p_n$ 上进行采样的,但是偏移量 Δp_n 通常是小数,无法准确获得所在位置的像素值,因此通过双线性插值法计算 x 的值,如式(6)~(8)所示:

$$g(a, b) = \max(0, 1 - |a - b|) \quad (6)$$

$$G(q, p) = g(q_x, p_x) \times g(q_y, p_y) \quad (7)$$

$$x(p) = \sum_q G(q, p) \times x(q) \quad (8)$$

其中, $p = p_o + p_n + \Delta p_n$ 表示偏移后的任意位置, $x(q)$ 表示特征图 F 相邻 4 个整数坐标的像素值, $G(\cdot, \cdot)$ 为四个坐标分别对应的权重。由上述分析可得,可变形卷积可以自适应确定接收域的大小和尺度,使采样形状更加贴近太阳能电池缺陷的形状和长度,提高模型的特征提取能力。

如图 5(b)所示,本文对图 5(a)原始 CBL 模块进行改进,将 CBL 模块中的标准卷积替换为可变形卷积,保证改进 CBL 模块仅增加少量计算量,就可以实现对目标的尺寸

和形状的准确采样。

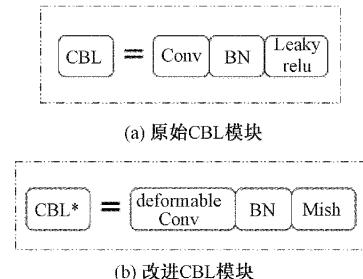


图 5 CBL 模块示意图

3) SimAM 注意力机制

太阳能电池缺陷图像除了缺陷信息还会存在大量的复杂背景信息。进行卷积操作时,复杂背景信息的叠加形成大量的多余信息会将缺陷信息掩盖,造成检测准确率较低。在检测模型中引入注意机制可以有效选择或强调物体的特征,提高有用特征的占比,抑制复杂背景干扰,有效解决这一问题。但是 SENet、ECANet 等常用注意机制只能生成 1-D 或 2-D 注意力权重,沿着空间或通道维度对特征进行细化,然而在人脑中是两种机制同时存在,因此现有注意力机制存在注意力权重在通道和空间灵活使用的局限性。通道注意力机制、空间注意力机制结构示意图分别为图 6 (a)、(b)所示。

Yang 等^[14]受人脑注意力机制的启发,提出一种即插即用的全三维权重的注意力模块 SimAM,并设计了一种能量函数计算每个神经元的权重,从而评估其重要程度。SimAM 注意力机制结构示意图如图 6(c)所示。值得注意的是,作者在论文中已经推导出能量函数的闭合求解形

式,实现不向网络添加参数的条件下加快权重计算,有助于检测模型轻量化运行,能量函数如式(9)所示。因此,本文引入了 SimAM 注意机制,并将其嵌入 YOLOv5s 检测模型颈部部分,使模型更加准确的识别缺陷类型以及定位缺陷位置。

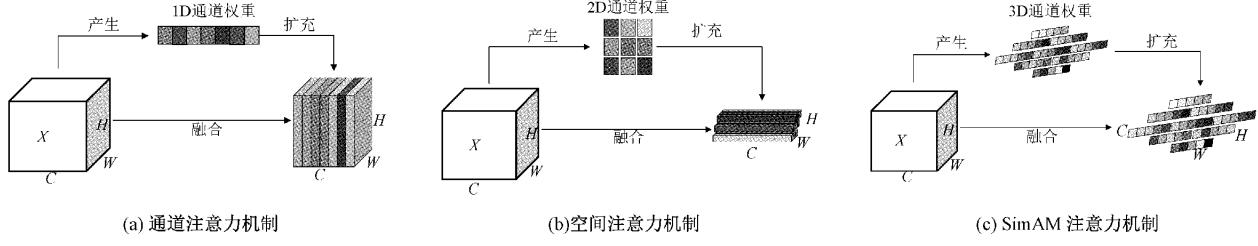


图 6 不同注意力结构示意图

SimAM 注意机制的最小能量函数如式(9)所示。

$$e_t^* = \frac{4(\sigma^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (9)$$

$$\hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i \quad (10)$$

$$\hat{\sigma}^2 = \frac{1}{M-1} \sum_{i=1}^M (x_i - \hat{\mu})^2 \quad (11)$$

其中, i 是空间维度上的指数, $M = H \times W$ 是该通道上的神经元数, $\hat{\mu}$ 和 $\hat{\sigma}^2$ 是该通道中除 t 以外所有神经元的均值和方差。 e_t^* 的计算值越小, 则神经元 t 与周围神经元的差别越大, t 神经元的重要程度越高, 因此神经元的重要程度可以通过最小能量函数的倒数 $1/e^*$ 得到。最后通过式(12), 对特征进行增强处理。

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (12)$$

为解决缺陷目标检测任务中, 不同卷积通道将过多的训练资源投入到非缺陷区域, 造成网络的训练效率低下的难题, 改进 YOLOv5 算法将 SimAM 注意机制引入颈部模块的末端。通过注意力机制计算每个通道神经元的重要程度, 并对其进行增强处理, 有效强调物体的特征, 改善重要信息丢失问题, 使检测模型的检测效果有效提升。

4) Hard-Swish 激活函数

选择合适的激活函数可以促进颈部结构有效地提取目标特征^[15-18]。SiLU(Swish)激活函数相比于 ReLU 激活函数具有更好的检测效果, 其公式为:

$$\text{Swish} = x \cdot \text{sigmoid}(\beta x) \quad (13)$$

Hard-Swish 激活函数是 SiLU 的改进形式^[19], 用 ReLU6 替代 SiLU 内的 Sigmoid 函数, 限制最大输出为 6。Hard-Swish 激活函数计算量更小并且在移动设备低精度情况下也具有表现优秀的分辨率, 激活函数表达式为:

$$\text{Hard-Swish} = x \cdot \frac{\text{ReLU}(x+3)}{6} \quad (14)$$

由公式和激活函数图像可得, Hard-Swish 激活函数具有非单调、有下界、无上界的特点, 它允许一部分负梯度流入保证信息流动, 并且可以避免 sigmoid、tanh 等激活函数具有的梯度饱和问题。由图 7 可以看出, Hard-Swish 具有优秀的梯度下降效果。

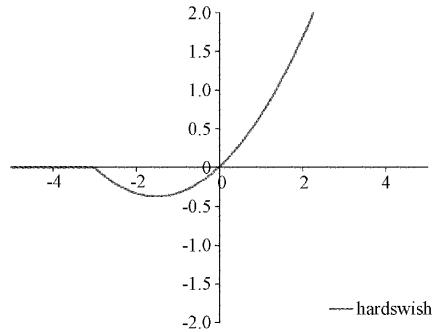


图 7 Hard-Swish 激活函数

5) K-means++聚类锚盒算法

YOLOv5 模型使用 K-means 算法对目标检测数据集进行聚类, 以训练集的边界作为基准, 使用锚盒作为先验框辅助预测目标尺寸。太阳能电池缺陷标注框的尺度大小和长宽比与常见公共数据集相差较大且 K-means 算法初始聚类时的聚类中心是随机选取的, 可能会导致初始聚类中心与最佳聚类中心位置相距很远, 不仅影响模型的收敛速度, 还会导致检测结果不佳^[20]。

为了解决传统方法聚类的局限性, 本文使用 K-means++聚类算法对标记的目标框进行多维聚类。K-means++聚类算法是对 K-means 算法的改进, 初始将其中的一个样本作为初始聚类中心, 然后计算每个样本到已有聚类中心的距离, 并将其分配到和已有聚类中心距离最短的类别中, 同时计算出每个样本为下一个聚类中心的概率, 选取概率最大的样本作为下一个聚类中心, 重复上述流程直到没有样本被分配到其它聚类中, 结束后挑选出 K 个聚类中心。K-means++聚类算法生成步骤如表 2 所示。

表 2 K-means+聚类算法流程

输入:训练集所有目标的宽高集合 N ,聚类中心 K

输出: K 组锚盒

步骤 1)从集合 N 中随机选择一个样本当作初始聚类中心;

步骤 2)计算 N 中所有样本与已有聚类中心的最短距离,并选取概率最大的样本为下一个聚类中心 C_i ;

步骤 3)重复步骤 2)直到找到 K 个聚类中心;

步骤 4)计算集合中的每个样本 x_i 到聚类中心的距离,并将其归类到最短距离聚类中的类别;

步骤 5)依据归类结果重新选择 K 个聚类中心;

步骤 6)重复步骤 4)和步骤 5),直到聚类中心确定,输出最终的聚类中心。

2.3 CIOU 损失函数

YOLOv5 为了提高模型的定位精度,使用 GIOU 作为回归损失函数,有效解决预测框和真实框不相交的情况,但是当两框出现包含情况或者长宽比不同时,GIOU 函数无法准确判断两个框的位置关系,造成模型定位产生很大误差^[21]。因此,改进 YOLOv5 检测模型使用 CIOU 函数作为回归损失函数,CIOU 函数能在边界框不重叠时为其提供移动方向,同时考虑重叠边界框的中心点距离、重叠面积和长宽比,在不增加计算成本的情况下,有效改进模型预测不准确的情况,其性能明显高于其他方法。CIOU 的计算公式如下:

$$IoU = IoU - \left(\frac{p^2(b, b^{gt})}{c^2} + \alpha v \right) \quad (15)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{\pi^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (16)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (17)$$

$$Loss_{CIOU} = 1 - IoU + \frac{p^2(b, b^{gt})}{c^2} + \alpha v \quad (18)$$

式中: b 和 b^{gt} 分别代表预测框和真实框的中心点, c 表示最小包围框对角线长度的平方, p 表示预测框和真实框两个中心点之间的欧氏距离, α 为权重系数, v 表示长宽比的相似性, w^{gt} 表示标注框的宽, h^{gt} 表示标注框的高, w 表示预测框的宽, h 表示预测框的高。

3 实验及结果分析

3.1 实验环境及数据

实验环境为 Windows 10 操作系统,使用 NVIDIA GeForce RTX 3070 Laptop GPU 8GB 显卡进行运算,CPU 配置为 Intel(R) Core(TM) i7-11800 H @ 2.30 GHz,CUDNN 版本为 11.0,Pytorch 版本为 1.7.1,python 语言环境为 3.6.0。

在模型训练中,通过 Adam optimizer 优化器对参数进行调优,设置目标的类别置信度阈值为 0.5,初始学习率为 0.01,动量为 0.937,采用余弦学习率衰减,权重衰减系数设置为 0.0005,防止过拟合现象的产生。此外,batch_size 设置为 16,共训练 400 个 epochs。

本文使用太阳能电池 EL 图片数据集进行训练,此数据集共 2534 张图像,图像的大小为 300×300 。在训练时按照 9:1 的比例,将此数据集随机划分为包含 2281 张图片的训练集和 253 张图片的测试集。利用标记软件 LabelImg 对数据集缺陷位置和类别进行标注,共有 crack(破裂)、finger(断栅)、black(实心黑)3 个标记类别。在标记过程中,将太阳能电池 EL 图像中的缺陷用矩形框包围,矩形框可以反应缺陷的具体位置和类别。注释以 PASCAL VOC 格式保存为 XML 文件。

3.2 算法评价指标

采用召回率(recall, R)、平均精度(average precision, AP)、平均精度均值(mean AP, mAP)、以及每秒检测图片的帧数(frames per second, FPS)作为评估指标对检测模型进行客观评估。上述评估指标计算公式如下所示。

$$AP = \int_0^1 P dR \quad (19)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (20)$$

$$Recall = \frac{TP}{TP + FN} \quad (21)$$

$$Precision = \frac{TP}{TP + FP} \quad (22)$$

TP(true positive) 表示缺陷图像被检测出缺陷的个数,TN(true negatives) 表示无缺陷图像被检测出缺陷的个数,FN(false negatives) 表示无缺陷图像被检测出无缺陷的个数,FP(false positive) 表示缺陷图像被检测出无缺陷的个数。AP 值是指 P-R 曲线面积,mAP 是通过实心黑、断栅、破裂 3 种缺陷的平均精度求均值得到的,检测中缺陷的类别数 $N=3$,且 mAP 的值越大,表示检测模型对缺陷的检测效果越好,识别精度越高。

3.3 实验结果与分析

1) 基础模型性能对比分析

本节主要探究模型的深度和宽度对太阳能电池缺陷检测 mAP 值的影响。在深度学习模型中,通常情况下模型结构越复杂、深度越深检测效果越理想。但是小样本数据未必会在最复杂的模型中表现出最优的检测效果。为了设计出性价比最高的模型,分别对 YOLOv5s、YOLOv5m、

YOLOv5l、YOLOv5x四种不同型号的模型进行训练,模型的各项指标如表3所示。

表3 4种模型的指标参数

模型类型	深度	宽度	mAP/%
YOLOv5s	0.33	0.50	81.79
YOLOv5m	0.67	0.75	82.64
YOLOv5l	1.00	1.00	82.33
YOLOv5x	1.33	1.25	80.92

实验结果表明 YOLOv5m 和 YOLOv5l 的检测效果均比 YOLOv5s 优异,但是最大 mAP 差距仅为 0.85%。综合考虑硬件要求以及检测精度等因素,我们仍选择 YOLOv5s 作为基础检测模型。

2)注意力机制对比分析

图8所示为不同注意力机制嵌入 YOLOv5s 检测模型 Neck 部分的检测结果对比,本次实验采用太阳能电池 EL 图像数据集进行训练。从图中可以看出 SimAM、SE-Net、ECA-Net 注意力机制引入 YOLOv5 模型后均可提升网络的检测精度,但是引入 CBAM 注意力机制后检测精度较原始算法下降。SimAM 注意力机制取得最优效果,相比原始算法提高 3.14%。

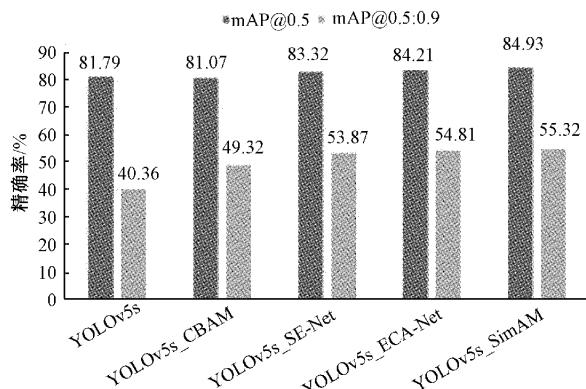


图8 各种注意力机制在YOLOv5s下的对比

综上所述,SimAM 注意力机制有效强调物体的特征,改善重要信息丢失问题,更适合高交并比下的目标检测任务。

3)改进算法与其他算法性能对比实验

本节选择改进 YOLOv5s 检测模型以及 5 种主流算法对太阳能电池缺陷进行检测,包括 YOLOv4、SSD、EfficientDet-D3、RetinaNet、Faster RCNN,本次实验采用太阳能电池 EL 图像数据集进行训练,实验数据如表4所示。

改进 YOLO v5s 模型在所有模型结构复杂度上表现最好,模型参数只有 YOLO v4 模型参数的 23.75%,mAP@0.5 为 89.86%,与其他检测模型相比精度至少提高 6.19%,FPS 达到 37.92,可以满足实际工程应用。RetinaNet 检测模型检测效果较好,但是在模型中使用大

表4 改进算法与其他算法性能对比结果

模型	参数 / M		FPS	P%	R%	mAP@ 0.5 / %
YOLOv4	64.0	14.55	88.64	95.19	81.39	
SSD	24.4	37.53	79.80	96.42	74.36	
EfficientDet-D3	11.9	42.36	86.32	94.86	82.76	
RetinaNet	55.5	24.21	88.06	95.77	83.67	
Faster RCNN	28.3	6.54	86.22	96.04	83.42	
改进算法	15.2	37.92	93.53	96.35	89.86	

量的深度可分离卷积层,造成模型参数数量过大,网络结构在对比模型中复杂程度最高,检测实时性难以满足。而二阶检测模型 Faster RCNN 与其他算法相比,其检测效果表现良好,但是检测速度较慢,无法满足工程实用要求。最后通过对比试验可以得出,改进 YOLO v5s 检测模型可以对太阳能电池缺陷有效检测,实现更好的检测性能。

4)消融实验

为了直观观察 K-means++聚类锚盒算法、混合数据增强、Hard-Swish 激活函数、SimAM 注意力机制、CIoU 损失函数、可变形卷积以及改进 SPP 模块对检测模型性能的影响,本节使用消融实验进行验证。本次实验在相同数据集、相同数量的训练世代条件下对检测效果进行比较,实验结果如表5所示。

如表5所示,混合数据增强改善原模型训练过程中存在的数据不足、欠拟合问题,改进后模型的 mAP 增幅明显;引入 SimAM 注意机制、可变形卷积和改进 SPP 模块部分后,检测模型特征提取感受野增大,采样点集中在缺陷区域,有效提高检测模型的特征提取以及保留重要信息的能力,改进后检测效果提升明显。K-means++聚类锚盒算法、CIoU 损失函数使检测模型重合框和定位更加准确,在一定程度上辅助改进算法更好地检测太阳能电池缺陷。

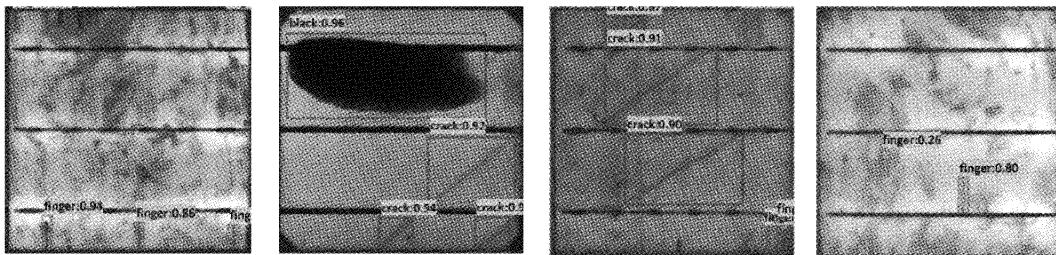
5)检测结果分析

本节随机选取不同类型的太阳能电池缺陷图像进行测试,YOLOv5s 检测模型和改进 YOLOv5s 模型的检测结果如图9所示。图9(a)为 YOLO v5s 模型检测结果,图9(b)为改进 YOLO v5 模型检测结果。从图9(a)中可以看出,在复杂背景的干扰下,YOLO v5s 出现了漏检情况,且置信度较低。而在图9(b)中,改进 YOLO v5s 模型没有受到非均匀、复杂背景的干扰,图片中的缺陷 100% 检出,检测框包围的位置更加准确,并且具有更高的置信度。通过对比可以看出,改进 YOLOv5s 模型检测结果更加准确,捕捉到更多的关键缺陷信息,具有优秀的泛化性能。

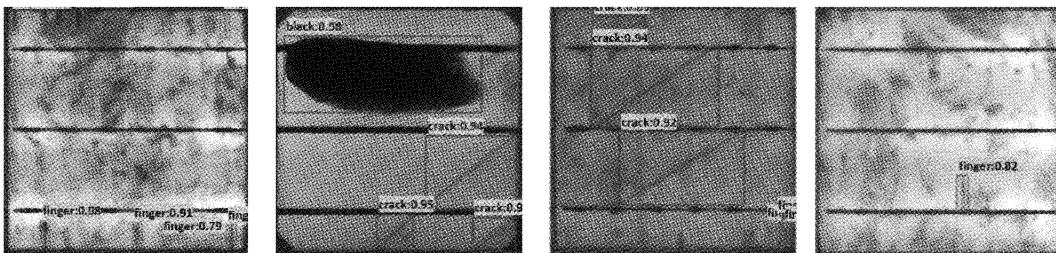
改进 YOLO v5s 检测模型对太阳能电池三种常见缺陷的 P/R 曲线如图10 所示。横轴和纵轴分别表示召回率和精确度,每类缺陷的 mAP 值为曲线和两坐标轴围成的面积。以 Recall=Precision 的点为平衡点,检测效果与平

表 5 消融实验统计结果

K-means++	混合数据增强	Hard-Swish	SimAM	CIOU	可变形卷积	改进 SPP	mAP@0.5/%	mAP 增加量
✓							81.79	
✓	✓						82.37	0.28
✓	✓	✓					83.34	1.55
✓	✓	✓	✓				83.72	1.93
✓	✓	✓	✓	✓			86.36	4.57
✓	✓	✓	✓	✓	✓		86.82	5.03
✓	✓	✓	✓	✓	✓	✓	88.47	6.68
✓	✓	✓	✓	✓	✓	✓	89.86	8.07



(a) YOLO v5s模型检测结果



(b) 改进YOLO v5s模型检测结果

图 9 YOLO v5s 和改进 YOLO v5s 检测结果对比

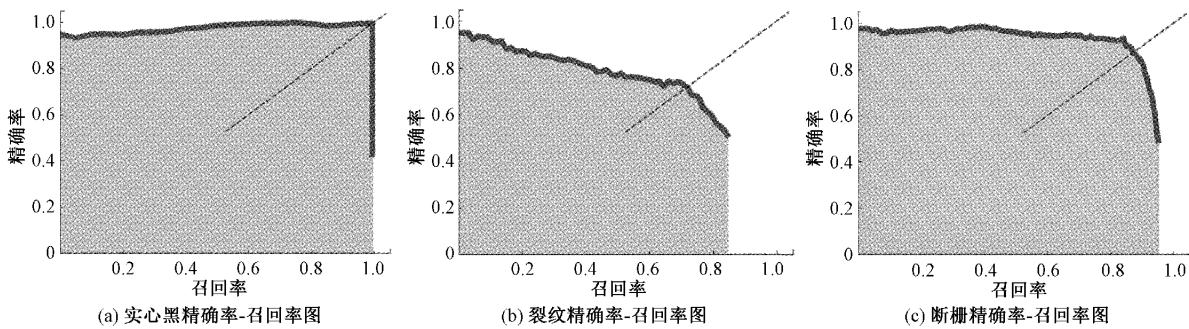


图 10 改进 YOLO v5s 检测模型精确率—召回率曲线图

衡点值成正比。从图 10(a)可以看出,由于实心黑缺陷面积大、纹理简单等特点,其 mAP 值接近 1。从图 10(c)可以看出,由于断栅形态为固定的垂直黑线,形状单一,检测效果也很好。但是从图 10(c)可以看出,裂纹缺陷形状多样,缺陷面积小,检测效果相对较差。图 11 展示了改进前后 YOLO v5s 检测模型 mAP@0.5 曲线图, YOLO v5s 曲线

在原始 YOLO v5s 曲线上方,这意味着改进的 YOLO v5s 网络的检测精度整体高于原始 YOLO v5s 网络,并且改进网络的学习曲线更加平滑,说明改进模型的稳定性更好。总体上来说,改进 YOLO v5s 检测模型,具有较高的准确率,优化了网络检测性能,能够较好地满足太阳能电池缺陷应用的需求。

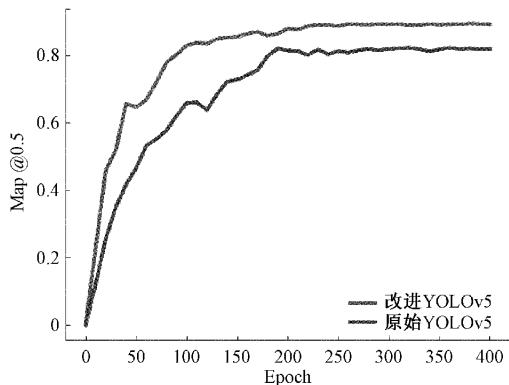


图 11 两种 YOLO v5s 检测模型 mAP@0.5 对比图

4 结 论

针对太阳能电池缺陷的特点提出一种基于 SimAM-Ada YOLOv5 目标检测模型,引入可变形卷积 CBL 模块、Ada Pool-SPP 模块、SimAM 注意力机制等方案增强特征提取能力,提高缺陷检测精度。同时使用马赛克和 MixUp 比例融合数据增强、K-means+十聚类锚盒算法、CIoU 损失函数以及 Hard-Swish 激活函数优化改进模型。通过对比实验、消融实验等方式表明,改进目标检测模型平均准确率达到 89.86%,比原始检测模型的 mAP 提高 8.07%,速度达到 37.92 fps,增强效果明显,保证了太阳能电池表面缺陷检测的效果。下一步的工作方向为降低模型复杂度,通过对检测模型网络剪枝、蒸馏等处理实现高检测速度,实现对模型轻量化改进。

参考文献

- [1] 周得永,高龙琴. 基于 YOLOv3 的太阳能电池板缺陷检测[J]. 南方农机,2022,53(4):142-144.
- [2] SANCHEZ-F P, ROPER F, LA L B, et al. Power losses in crystalline silicon pv modules due to cell interconnection[C]. 23rd European Photovoltaic Solar Energy Conference and Exhibition, 1-5 September 2008, Valencia, Spain, 2008.
- [3] DU B, YANG R, HE Y, et al. Nondestructive inspection, testing and evaluation for Si-based, thin film and multi-junction solar cells: An overview[J]. Renewable and Sustainable Energy Reviews, 2017,78: 1117-1151.
- [4] SU B, CHEN H, ZHU Y, et al. Classification of manufacturing defects in multicrystalline solar cells with novel feature descriptor[J]. IEEE Transactions on Instrumentation and Measurement, 2019,68(12): 4675-4688.
- [5] 范程华,王群京,曹欣远,等. 基于信号突变点校正的太阳能电池片缺陷检测方法[J]. 激光与光电子学进展, 2020,57(6):246-251.
- [6] 雷泰,柳宁,李德平,等. 激光刻写零件瑕疵图像在线检测算法[J]. 计算机集成制造系统, 2020, 26 (2): 356-365.
- [7] LIU L, ZHU Y, RAHMAN M, et al. Surface defect detection of solar cells based on feature pyramid network and GA-Faster-RCNN[C]. 2019 2nd China Symposium on Cognitive Computing and Hybrid Intelligence(CCHI), 2019.
- [8] LI S, LI Y, LI Y, et al. YOLO-FIRI: Improved YOLOv5 for infrared image object detection[J]. IEEE Access, 2021(99):1-1.
- [9] 鲁东林,王淑青,鲁濛,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.
- [10] 王淑青,张鹏飞,要若天,等. 基于改进 YOLOv5 的太阳能电池片表面缺陷检测[J]. 仪表技术与传感器, 2022(5):111-116.
- [11] 郎松,曹选,张艳微,等. 融合改进 YOLOv5 算法的图像全站仪全自动测量方法[J]. 仪器仪表学报, 2022, 43(5):120-127.
- [12] STERGIOU A, POPPE R. AdaPool: Exponential adaptive pooling for information-retaining downsampling[J]. ArXiv Preprint, 2021, ArXiv:2111.00772.
- [13] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[J]. IEEE, 2017, DOI: 10.1109/ICCV.2017.89.
- [14] YANG L, ZHANG R Y, LI L, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks[C]. International Conference on Machine Learning, PMLR, 2021.
- [15] 苏佳,贾欣雨,侯卫民. 基于 YOLO-J 的 PCB 缺陷检测算法[J/OL]. 计算机集成制造系统:1-20[2023-05-31].
- [16] 马燕婷,赵红东,阎超,等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8):150-157.
- [17] 叶翔,孙嘉兴,甘永叶,等. 改进 YOLOv3 模型在无人机巡检输电线路部件缺陷检测中的应用研究[J]. 电测与仪表, 2023,60(5):85-91.
- [18] 孟志超,贺磊盈,杜小强,等. 基于 Enhanced VGG16 的油茶品种分类[J]. 农业工程学报, 2022,38(10):176-181.
- [19] 黄凤琪,陈明,冯国富. 基于可变形卷积的改进 YOLO 目标检测算法[J]. 计算机工程, 2021,47(10):269-275,282.
- [20] REZAYOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), IEEE, 2019.

作者简介

尹丽菊(通信作者),博士,教授,主要研究方向为光电检测技术(微光探测)、光子计数成像与机器视觉、目标检测等。
E-mail:55660487@qq.com

张猛,硕士研究生,主要研究方向为目标检测与深度学习。

E-mail:zczmeng@126.com