

DOI:10.19651/j.cnki.emt.2519855

基于改进 YOLOv11n 光伏板缺陷检测算法^{*}

张 天 崔博文 崔鑫淼

(沈阳建筑大学机械工程学院 沈阳 110168)

摘 要: 针对 YOLOv11n 在光伏(PV)板缺陷检测中漏检、检测精度低的问题,提出了一种基于改进 YOLOv11n 的光伏板缺陷检测算法,设计 SPPF-LDESKA 模块,对快速空间金字塔池化模块(SPPF)进行改进,借鉴轻量化细节增强卷积结合模型轻量化与细节特征强化思想的卷积结构,融合大型可分离核注意力机制增强感受野,有效增强对小目标信息的提取能力;特征金字塔网络(FPN)模块借鉴上下文引导的特征调制(CGFM),设计高效共享卷积模块(ESCM)融合架构,融入高效共享卷积模块(ESCM)机制,通过一维卷积在通道维度进行局部交互,结合共享参数卷积降低冗余计算,避免重复学习,减少参数量,提高多尺度特征融合中上下文信息的自适应调整;设计轻量化检测头,使用共享卷积减少模型的参数量。实验结果表明,与 YOLOv11n 模型相比,计算量降低了 6.25%,精度提升 4.5%,mAP@50 从 87.5%提升到了 89.5%,提升了 2.3%,证明改进后的算法能够更好地应用在光伏板缺陷检测的任务中。

关键词: 缺陷检测;光伏板;空间金字塔池化;注意力机制;特征金字塔网络;共享卷积;YOLOv11n

中图分类号: TP391.4;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 460.99

Photovoltaic panel defect detection algorithm based on improved YOLOv11n

Zhang Tian Cui Bowen Cui Xinmiao

(School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang 110168, China)

Abstract: To address the problems of missed detections and low detection accuracy of YOLOv11n in photovoltaic (PV) panel defect detection, this paper proposes an improved YOLOv11n-based PV panel defect detection algorithm. A novel SPPF-LDESKA module is designed to enhance the original spatial pyramid pooling fast (SPPF) module. The module integrates the concepts of lightweight detail-enhanced convolution, which combines model lightweighting and fine-grained feature enhancement—with a large separable kernel attention mechanism to expand the receptive field and effectively strengthen the extraction of small-object information. In the feature pyramid network (FPN) stage, inspired by the context-guided feature modulation (CGFM), an efficient shared convolutional module (ESCM) is designed. This module incorporates the efficient channel attention (ECA) mechanism, employing 1D convolution along the channel dimension to perform local inter-channel interaction. Furthermore, shared convolution is utilized to reduce redundant computation and prevent repetitive learning, thereby decreasing the parameter count and enhancing the adaptive adjustment of contextual information in multi-scale feature fusion. Additionally, a lightweight detection head is introduced, leveraging shared convolution to further reduce model parameters. Experimental results demonstrate that, compared with the original YOLOv11n model, the proposed method reduces computational cost by 6.25%, accuracy improved by 4.5%, while mAP@50 improves from 87.5% to 89.5%, achieving a 2.3% performance gain. These results validate that the improved algorithm achieves superior performance and better adaptability for PV panel defect detection tasks.

Keywords: defect detection; photovoltaic panels; spatial pyramid pooling; attention mechanisms; characteristic pyramid network; shared convolutions; YOLOv11n

0 引 言

“2030 年碳达峰,2060 年碳中和”是我国能源战略转型

的重大战略决策,标志着我国进入关键阶段^[1]。光伏板作为太阳能发电系统的核心组件,其性能和质量直接影响着发电效率和安全性^[2]。实验室模拟数据显示,划痕和断栅

收稿日期:2025-09-15

^{*} 基金项目:国家自然科学基金(52075348, 52175107, 52275119)、辽宁省揭榜挂帅科技攻关专项(2022JH1/10400028, 2023JH1/10400043)、沈阳市“揭榜挂帅”产业共性技术项目(22-316-1-17)资助

等缺陷会显著影响光伏组件性能:0.5 mm 宽、0.1 mm 深的划痕可导致局部效率下降 5%~8%,平均年功率衰减率达 2.8%,使用寿命缩短 3~5 年;断栅则阻碍电流传输,易引发热斑效应,严重时可能导致火灾;此外,组件每升高 1℃,输出功率下降约 0.4%~0.5%,而高温高湿环境下的脏污还可能诱发 PID 效应,加速功率衰减。所以,准确且高效地检测出光伏板的缺陷类别尤为重要。

深度学习中的目标检测模型主要分为两种:一阶段算法如 YOLO(you only look once)系列等直接预测目标框和类别,以及二阶段算法如 Faster-RCNN 先生成候选区域再进行分类与回归^[3]。在图像处理方面,赵强等^[4]基于 HSV 空间模型的 K 均值聚类方法处理光伏板红外图像;Et-taleby 等^[5]采用 K-means 算法进行太阳能电池板故障检测,通过将图像像素划分为高相似性的区域,实现了较好的检测效果。而对于图像处理时人工成本较高,算法计算量复杂,对设备要求较高,难以实现较为准确的缺陷检测。

基于此,应用卷积神经网络进行识别光伏板缺陷兴起。钟冰松等^[6]结合 SSD 与 YOLOv3 算法,SSD 准确率达 83.8%,但速度较慢;李瑞瑞等^[7]改进 Faster R-CNN,采用 BiFPN 和轻量注意力模块,提高热斑故障检测精度;赵晓雨等^[8]将高效通道注意力(the efficient channel attention, ECA)嵌入 YOLOv5 的 C3 模块,降低参数同时提高精度;Zhang 等^[9]将先进卷积技术整合至 YOLOv7,增强模型检测能力;李冰等^[10]提出 MAFPN 网络,设计 FEM 与 AFM 模块并融合注意力机制,更精准捕捉关键信息与细节;张文强等^[11]等设计 C2f-ELA 与 W-BiFPN 模块,加强多尺度与局部特征提取,显著提升小目标识别能力。

基于 YOLOv11n 模型兼具轻量化与高精度的特性,具备良好的实时检测能力和部署灵活性。相比前代模型, YOLOv11n 在主干网络和特征融合结构上进行了优化,具有更强的特征表达能力和多尺度检测性能。但其在小目标检测和复杂场景下仍存在一定提升空间,为本文的改进研究提供了良好的基础。近期,基于 YOLOv11n 的多尺度特征融合与轻量化改进中,明显提升小目标(裂纹、微小焊点)检测精度,同时保持接近实时的推理速度。在若 PV 数据集上 Precision 与 mAP 有显著提升,但由于多尺度融合增加了中间特征处理开销,若在极端嵌入式平台上仍需做剪枝或量化。针对于以下两种问题,特征提取中细节特征需要增强及模型的轻量化,同时要保持模型的实时性,提出一种改进的光伏板缺陷检测算法。

1 改进 YOLOv11n 模型

1.1 YOLOv11n 模型介绍

YOLOv11n 是 2024 年 9 月 Ultralytics 发布 YOLO 系列的版本。具有轻量级的目标检测网络结构,主要组成部分包括:主干网络(Backbone)、中间特征聚合层(Neck)、检测头(Head)^[12],其结构如图 1 所示。




图 1 YOLOv11n 网络结构
Fig. 1 YOLOv11n network structure

在 Backbone 中,引入了 C3k2 模块作为特征提取单元,该模块为 CSP(cross stage partial)结构的改进形式。C3k2 通过划分特征图并在不同分支中应用多个 3×3 卷积核,实现更高效的信息流传递,同时显著减少参数量与计算复杂度。YOLOv11n 引入 C2PSA 模块以提升特征表达能力。该模块集成了两个并行的 PSA (position-sensitive attention)分支,通过空间注意力机制增强模型对关键区域的响应能力,从而提升检测精度。在 Neck 部分,模型采用 PAN(path aggregation network)结构,并融合 C3k2 模块以实现多尺度特征的高效聚合与传递。Head 部分延续了 YOLOv8 的检测头设计,在分类分支中引入深度可分离卷积,以进一步提升计算效率与模型性能。

1.2 改进 YOLOv11n 算法

1)改进算法的结构

针对于 YOLOv11n 在光伏板缺陷检测中漏检与精度不足等情况,提出的改进算法,如图 2 所示。在主干网络提取中,将快速空间金字塔池化(spatial pyramid pooling-fast, SPPF)模块与重新设计的大型可分离核注意力机制(large separable kernel attention,LSKA)结合,借鉴轻量化细节增强卷积 LDEConv 结合模型轻量化与细节特征强化思想的卷积结构,来捕捉图像的广泛上下文信息,生成注意力图,并通过这个注意力图加权原始特征,以此增强网络对于重要特征的关注度,提高模型的性能;在特征金字塔网络(feature pyramid networks,FPN)的基础上借鉴上下文引导的特征调制(context-guided feature modulation, CGFM),减少多尺度融合带来的模型的高复杂度。通过引入上下文感知与自适应调节机制,结合 ECA 与共享卷积模式,设计高效共享卷积模块(efficient shared convolutional module,ESCM),能够在融合过程中突出关键信息并抑制

冗余特征,从而增强特征表征能力。另外,在检测头部分提出轻量级共享卷积检测头(lightweight shared convolutional detection head, LSCD),在保证检测精度的同时有效降低模型复杂度。




图 2 改进 YOLOv11n 网络结构

Fig. 2 Improved YOLOv11n network structure

2) SPPF_LDESKA 模块

由于加工材料与生产工艺的限制,光伏板不可避免地会出现大小不等的破损、裂纹和斑点等缺陷。SPPF 模块允许网络处理各种尺寸的输入图像,而无需将图像调整到固定大小,避免了因图像调整而导致的失真或信息丢失。SPPF 旨在融合局部与全局特征以捕捉多尺度信息,在光伏板缺陷检测中,因缺陷区域较小,SPPF 的池化操作可能导致小目标特征细节丢失,从而影响检测精度。因此,引入 LSKA 并设计轻量化细节增强卷积对 LSKA 与 SPPF 结合的改进,SPPF 及 LSKA 结构如图 3 所示。

LSKA 机制通过结合可分离卷积、扩张卷积和注意力机制,具有局部敏感性的核函数,旨在降低计算成本的同时提升模型性能^[13]。首先,输入特征图分别通过两个可分离卷积层提取水平方向与垂直方向的局部特征,有效减小了参数量。然后,引入扩张卷积以扩大感受野,使模型能够获取更丰富的全局上下文信息,增强对长距离像素间依赖关系的建模能力,有助于提升模型对复杂结构和小目标的识别能力。通过一个 1×1 的卷积生成空间注意力图,对不同区域的特征进行动态加权。最后,将该注意力图与原始特征图逐元素相乘,得到加权后的特征表示,使模型能够自适应地聚焦于更为关键区域。其中 LSKA 部分的输出




图 3 SPPF 及 LSKA 结构

Fig. 3 SPPF and LSKA structures

如式(1)~(4)所示。

$$Q^C = \sum_{H,W} K_{(2d-1) \times 1}^C * (\sum_{H,W} K_{1 \times (2d-1)}^C * F^C) \quad (1)$$

$$T^C = \sum_{H,W} K_{\lfloor \frac{k}{d} \rfloor \times 1}^C * (\sum_{H,W} K_{1 \times \lfloor \frac{k}{d} \rfloor}^C * X^C) \quad (2)$$

$$A^C = K_{1 \times 1} * T^C \quad (3)$$

$$E^C = A^C \otimes F^C \quad (4)$$

式中: $*$ 和 $\otimes$ 分别表示卷积和哈达玛积; Q^C 为深度卷积的输出, C 代表卷积的缩写, d 为膨胀率,其核大小为 $(2d-1) \times (2d-1)$,捕获局部空间信息,并对深度卷积的网格效应进行补偿^[14]。将核为 $k \times k$ 的卷积与输入特征图得到深度卷积 T^C ,在进行 1×1 卷积得到注意力图 A^C , LSKA 的输出 E^C 是注意力图 A^C 和输入特征图 F^C 的哈达玛乘积。

轻量化细节增强卷积(LDEConv)是结合模型轻量化与细节特征强化思想的卷积结构,改进 LSKA 注意力机制旨在保证较低计算量和参数量的前提下,提高模型对图像局部纹理、边缘和小目标细节的感知能力。LDEConv 结构如图 4(a)所示。

LDEConv 由两个核心部分组成:差分特征增强(differential detail enhancement)^[15] 借鉴差分卷积(differential convolution, DC)思想,通过计算像素或特征间的局部差异强化细节响应:

$$D(x) = |x - \text{avgpool}(x)| \quad (5)$$

该差分特征再与原特征进行融合,以保留结构纹理信息。轻量化卷积模块(lightweight convolution block)使用深度可分离卷积(depthwise separable Conv)、逐通道卷积(pointwise Conv) 1×1 来减少计算量;并结合注意力机制 LSKA 实现特征重标定,采用深度可分离,大幅减少 FLOPs 与参数量,差分增强分支有效捕获局部变化与细节特征,从而提升有用细节的表达。结合后其 SPPF-LDESKA 网络结构如图 4(b)所示。小目标缺陷检测精度提升;模型能自适应选择关注区域;保持较低计算成本,达到轻量化设计要求的同时增强鲁棒性。

3) ESCM 模块

但在光伏板缺陷检测任务中,网络需要面对的是不同




图 4 LDEConv SPPF-LDESKA 结构

Fig. 4 LDEConv and SPPF-LDESKA structure

尺度的目标,传统的卷积层无法完全适应各种尺度的缺陷,不能进行灵活调整,故而难以准确地捕捉缺陷,在提取不同尺度的缺陷特征时,往往存在着有效信息的丢失。YOLOv11n 虽引入了新型卷积机制,但传统卷积因固定卷积核和层堆叠方式,受限局部感受野,难以捕捉远距离

像素间的依赖关系,导致全局上下文信息提取不足。因此,引入 CGFM 模块,旨在扩大模型的感受野并增强全局上下文信息的提取能力^[16]。CGFM 模块能够有效捕捉远距离依赖关系,从而为小目标检测提供更丰富的全局上下文信息支持,网络结构如图 5 所示。




图 5 CGFM 结构

Fig. 5 CGFM structure

在特征融合模块中,输入特征图 $T \in \mathbf{R}^{H \times W \times C}$ 首先经过 3×3 卷积操作,以减小空间维度并扩展通道数,得到新的特征图 $T' = \mathbf{R}^{\frac{H}{2} \times \frac{W}{2} \times 2C}$ 。随后,特征图被输入至 CGFM 模块以进行深度融合处理。模块内部首先通过 1×1 卷积实现通道信息整合与线性映射,然后分为两条平行分支:第 1 分支采用 3×3 卷积以捕获图像的局部细节与边缘信息,第 2 分支则利用 3×3 空洞卷积扩大感受野,从更广的上下文中提取关联特征。两分支的特征在通道维度上拼接后,经过批量归一化(BN)和带参数的 PReLU 激活函数进行融合,以提升非线性表达能力并抑制特征冗余。融合特征经全局平均池化(GAP)压缩空间维度后,依次通过两层全连接层建模通道间依赖关系,生成的注意力权重与原始特征进行逐元素加权,最终输出特征图 $T'' = \mathbf{R}^{\frac{H}{4} \times \frac{W}{4} \times 2C}$,有效结合了局部与全局上下文信息,提升模型对多尺度目标的表达能力。

针对以上对全局上下文信息处理,逐层卷积操作相对繁琐,结合前人通过 SE(squeeze-and-excitation)注意力机

制改进,该注意力机制由 Hu 等^[17]在 2018 年提出,其核心是将显式建模通道之间的依赖关系,实现特征的自适应重标定。SE 模块由 Squeeze 与 Excitation 两个阶段构成,前者通过全局平均池化压缩空间信息以获得全局语义,后者利用全连接层与激活函数建模通道依赖并分配权重,全局信息的提取增加了模型的复杂度,难以实现模型轻量化要求,标准卷积(convolution, Conv)对所有输入通道进行卷积处理,其参数量与计算量大,效率低。因此,在 CGFM 中,使用 ECA^[18]替代原通道注意力部分(context weighting 部分)通过一维卷积(1D Conv)在通道维进行局部交互,实现无全连接、无维度压缩的注意力机制结合共享参数卷积(shared-weight convolution)降低冗余计算,通过参数共享(weight sharing),可避免重复学习同类特征,从而减少参数量。相比仅依赖局部感受野的传统卷积结构,ECA 注意力机制以轻量化的方式有效提升了特征表达能力与网络鲁棒性。

上下文引导融合模块 CGFM 架构对特征金字塔网络(FPN)进行改进,ESCM 结构如图 6 所示,通过上下文引导

与自适应调控,并结合 ECA 注意力机制及共享卷积,通过通道权重重构突出关键信息、抑制冗余特征,从而显著增强特征表征与判别能力,提升目标检测精度。




图 6 ESCM 结构
Fig. 6 ESCM structure

4)检测头模块

在 YOLOv11n 检测网络的 Detect 模块中,采用 4 个 3×3 卷积与 2 个二维卷积以增强深层特征提取能力,但增加了网络结构的复杂度。为降低 Detect 模块的参数量与计算开销,同时尽可能保持检测精度,设计了一种轻量级 LSCD^[19],其结构如图 7 所示。




图 7 LSCD 结构
Fig. 7 LSCD structure

该模块采用轻量级共享卷积结构,通过引入 Conv_GN 与 Conv2d 操作,有效减少传统检测头中的冗余计算。通过处理多个检测层,实现对多尺度目标的建模,每个检测层对应不同感受野范围,从而提升对不同尺寸目标的感知能力。与其原有的检测头对比,如表 1 所示,其中 GFLOPs 为计算量、mAP50 为平均精度 50%。整体设计在降低参数量与计算开销的同时,尽可能减少精度损失。

表 1 检测头对比

Table 1 Comparison of detection heads

模型	GFLOPs	mAP50/%
Detect-Head	6.3	88.0
Detect-LSCD	5.6	88.5

2 实验与分析

2.1 图像数据集

本次实验使用的数据集是在百度飞桨公开数据集,数据集包含 2 400 张图片,图像的分辨率为 640 pixel×640 pixel,以“JPG”为格式。在该数据集上一共有 3 种缺陷,分别为划痕(Crack)、断栅(Grid)、脏污(Spot)。本次实验中对该数据集按 8:2 进行划分,训练集 1 920 张图片,验证集 480 张图片。

2.2 试验环境与参数配置

本次试验在 Windows11 操作系统下进行训练,训练的硬件环境是 NVIDIA GeForce RTX4060,16 GB 显卡的图像处理器(GPU),通过 CUDA12.4 版本对 GPU 进行加速,深度学习框架为 Pytorch1.7.1,批量大小(batch size)为 8,线程数(works)为 8,采用随机梯度下降(SGD)进行训练,epochs 为 200,初始学习率为 0.001,其他参数设置默认值,相关实验配置如表 2 所示。

表 2 实验配置

Table 2 Experimental configuration

类别	配置
CPU	AMD Ryzen 9 7945HX
GPU	NVIDIA GeForce RTX 4060 8 G
内存(RAM)	16 G
操作系统	Windows 11
深度学习框架	PyTorch 1.7.1
编程环境	Python 3.9
CUDA	12.4

2.3 模型评价指标

为了全面评估本文方法的性能和模型的整体情况,采用以下 5 个评价指标对本文模型进行评估:精度(precision,P)、召回率(recall,R)、参数量(parameters)、计算量(GFLOPs)以及均值平均精确度(mean average precision,mAP)。mAP50 表示在 IoU 阈值为 0.5 时,各类别平均精度(average precision,AP)的均值,用于衡量目标检测模型在该阈值下的整体检测性能。

精度定义为:

$$P = \frac{TP}{TP + FP} \tag{6}$$

式中:TP(true positive)为正确预测的正样本数,FP(false positive)为错误预测的正样本数。

召回率表示实际为正样本中,被正确预测的比例,召回率公式为:

$$R = \frac{TP}{TP + FN}$$

(7)

式中:FN(false negative)为未被检测到的真正正样本数。召回率越高,模型漏检越少。

参数量(parameters):模型的总参数数目,用于衡量内存占用。GFLOPs:每秒浮点运算次数,反映模型计算复杂度,值越低表示计算效率越高。平均精度(AP):通过精确率-召回率曲线下的面积评估模型在单类目标检测中的性能。平均平均精度(mAP):各类别 AP 的平均值,用于综合评估模型在多类别检测任务中的整体性能。

$$AP = \int_0^1 p(r)dr$$

(8)

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

(9)

2.4 实验结果分析

1)主干网络模块对比实验分析

为验证不同主干模块对模型性能的影响情况,在YOLOv11n 的基础上,对主干提取部分利用差分特征增强原理中深度可分离卷积与逐通道卷积对LSKA 内部的1×1卷积进行改进方案为I实验,利用LDEConv 卷积思想只使用深度可分离卷积并融合LSKA 注意力机制进行改进方案为II实验,利用LDEConv 卷积思想只使用逐通道卷积并融合LSKA 注意力机制进行改进方案为III实验,SPPF-LSKA 模块及本文改进的结合模型轻量化与细节特征强化思想的卷积结构,融合LSKA 注意力机制进行对比实验,实验结果如表3所示。

表 3 主干网络模块对比实验

Table 3 Comparison experiments of backbone network modules

模型	P/ %	R/ %	Parameters/ M	GFLOPs	mAP50/ %
YOLOv11n	85.0	83.8	2 590 425	6.4	87.5
I	81.6	75.8	2 343 537	5.7	80.1
II	85.2	83.0	3 411 809	8.6	87.2
III	86.4	81.4	3 161 045	6.3	86.0
SPPF-LSKA	86.5	83.5	2 855 633	6.5	88.0
SPPF-LDESKA	86.8	83.2	2 485 854	6.3	88.5

由表3可知,相较于试验I、II、III,在原模型中引入SPPF-LDESKA 模块后,其在P为86.8%、mAP50为88.5%等指标上较优,整体性能优于其他模块。尽管其参数量与计算量并非最优,R略低于SPPF-LSKA 的

83.5%,但在主干特征提取中能够有效保证光伏板缺陷的信息表达与检测精度尤为重要。

2)特征融合模块对比实验分析

为验证不同特征融合模块对模型性能的影响情况,在原改进模型的基础上仅将SE 注意力机制替换为ECA 通道注意力机制通过一维卷积(1D Conv)在通道维进行局部交互设为改进方案IV,改进方案V为仅结合共享参数卷积(shared-weight convolution)降低冗余计算,通过参数共享(weight sharing),可避免重复学习同类特征,从而减少参数量与原改进模型CGFM 及结合以上IV、V两种方案所设计的ESCM 融合机制进行对比实验,实验结果如表4所示。

表 4 特征融合模块对比实验

Table 4 Comparison experiments of the feature fusion module

模型	P/ %	R/ %	Parameters/ M	GFLOPs	mAP50/ %
YOLOv11n	85.0	83.8	2 590 425	6.4	87.5
IV	87.3	80.2	2 322 802	6.5	87.3
V	83.5	84.0	2 668 881	6.8	87.5
CGFM	87.0	81.8	2 238 897	6.3	88.8
ESCM	88.0	82.4	2 488 546	6.3	89.7

由表4可知,相较于试验IV、V及CGFM 和ESCM 模块融入ECA 通道注意力机制,结合共享参数卷积(shared conv)后,mAP50 提升至89.7%。在保持精度与mAP50 较高,计算量为6.3 GFLOPs,实现了平均精度的提升。虽参数量及R不是最低,但性能增益合理,表明CGFM 的改进契合光伏板缺陷检测任务需求。

3)检测头对比实验分析

为验证检测头对性能的影响,在原模型基础上分别针对轻量化设计要求引入DyHead^[20]、高效检测头 Detect-Efficient、轻量化非对称性检测头 Detect-LADH^[21]与轻量级共享卷积检测头 Detect-LSCD 进行对比实验,实验结果如表5所示。

表 5 检测头对比实验

Table 5 Comparison experiment of detection heads

模型	P/ %	R/ %	Parameters/ M	GFLOPs	mAP50/ %
DyHead	86.9	84.5	2 587 588	6.0	86.5
Detect-Efficient	87.7	84.2	2 599 675	6.0	87.8
Detect-LADH	88.0	85.8	2 558 776	5.9	88.0
Detect-LSCD	88.6	85.3	2 420 622	5.9	88.5

由表5可知,相较于以上检测头 Detect-LSCD 检测头

在各项指标上均表现较好, P 为 88.6%、mAP50 为 88.5%,且显著降低了参数量与计算量,虽 R 为 85.3%,但与 Detect-LADH 检测头相差不大,因此,将其应用于生产线有助于实现缺陷的实时检测,并提升模型的精度与整体性能。

4)消融实验

为进一步验证改进算法的有效性,开展消融实验,结果如表 6 所示,其中“√”表示该组合包含相应模块。

表 6 消融实验
Table 6 Ablation experiment

模型				$P/\%$	$R/\%$	Parameters/M	GFLOPs	mAP50/ %
YOLOv11n Baseline	SPPF-LDESKA	ESCM	Detect-LSCD					
√				85.0	83.8	2 590 425	6.4	87.5
√	√			86.8	83.2	2 485 854	6.3	88.5
√		√		88.0	82.4	2 488 546	6.3	89.7
√			√	88.6	85.3	2 420 622	5.9	88.5
√	√	√		85.5	82.8	2 600 520	6.3	88.3
√	√	√	√	88.8	84.1	2 461 764	6.0	89.5

5)不同模型对比实验分析

为进一步验证改进模型的性能,与现有主流模型在同

数据集上进行对比实验,结果如表 7 所示,其中帧数为 (farthest point sampling,FPS)。

表 7 不同模型对比实验
Table 7 Comparison of different models

模型	$P/\%$	$R/\%$	Parameters/M	GFLOPs	mAP50/%	FPS
Faster RCNN	75.8	80.1	135 952 652	356.2	68.5	28
YOLOv5s	84.5	84.5	21 357 524	25.2	85.8	58
YOLOv7	84.6	85.8	37 889 766	145.2	85.6	93
YOLOv8n	85.5	83.3	3 006 233	8.1	87.4	94
YOLOv10n	85.6	82.0	2 708 210	8.4	87.5	98
YOLOv11n	85.0	83.8	2 590 425	6.4	87.5	102
YOLOv12s	86.5	83.2	2 601 567	6.4	86.8	101
DT-DETR	86.6	83.5	2 750 664	6.5	87.4	107
本文	88.8	84.1	2 461 764	6.0	89.5	118

由表 7 可知,在不同模型及改进模型的性能对比中,虽 Faster R-CNN、YOLOv5s 和 YOLOv7 检测精度较高,但其参数量大、计算复杂度高;改进后模型更加轻量化,处理速度更快,帧数最高为 118。与 YOLOv8n 相比,参数量减少 0.44 M,计算量下降 2.1 GFLOPs, mAP50 提升 2.4%;与 YOLOv10n 相比,参数量减少 0.145 M,计算量

下降 2.4 GFLOPs, mAP50 提升 2.3%;YOLOv12s 精度与召回率相差不大,但参数量稍大且平均精度不高。DT-DETR 模型的精度达到要求,但其模型计算量大且平均精度稍低。而本文的改进模型相较原 YOLOv11n,参数量略降 0.13 M,计算量由 6.4 GFLOPs 降至 6.0 GFLOPs,提升 6.25%,同时精度提升 4.5%及 mAP50 提升 2.3%。实

验表明,改进模型在减少漏检、提升检测精度、收敛速度和平均精度方面均优于现有主流模型^[22]。

为进一步展示本文所提方法的有效性与可靠性,在所有对比实验中取 3 组分别为 YOLOv10n、YOLOv11n 与本

文对检测结果进行可视化的试验,如图 8 所示,为验证所提出模型的泛化性将其设计模型运用在北京大学智能机器人开放实验室发布的 PCB 瑕疵数据集进行试验,试验结果如表 8 所示^[23]。




图 8 检测结果
Fig. 8 Detection results

表 8 试验结果			
Table 8 Test results			
模型	mAP50/%	Parameters/M	FPS
Faster RCNN	90.8	125 952 666	25
YOLOv5s	85.3	2 237 524	56
YOLOv7	88.1	37 789 756	99
YOLOv8n	91.1	3 185 233	92
YOLOv10n	92.8	2 691 209	97
YOLOv11n	93.5	2 590 425	101
YOLOv12s	94.8	2 601 567	103
DT-DETR	94.3	2 550 664	105
本文	95.4	2 361 764	117

结果表明,所提出的针对于光伏板缺陷检测算法在 PCB 瑕疵数据集上亦能展现出优良的检测性能。其 mAP50 和 FPS 指标均优于 Faster R-CNN、SSD、YOLOv5s 等一系列主流目标检测模型,展现出了良好的泛化性,验证了改进策略的普适性。如图 9 所示,展示了原模型与改进后模型的损失函数、mAP50 和 mAP50-95 对比图。在图 9(a)、(b)中可以看出本文曲线比原模型曲线收敛速度更快;在图 9(c)、(d)中改进后的模型 mAP50 和 mAP50-95 曲线明显高于原模型。改进后的算法表现出更快的收敛性与更高的检测精度,同时兼具良好的实时性,能够有效满足光伏产业对检测效率与准确性的需求^[12]。




图 9 改进模型与 YOLOv11n 模型效果对比

Fig. 9 Comparison of improved model and YOLOv11n model performance

3 结 论

针对目前光伏板缺陷检测算法模型中,对小目标检测精度低、计算成本要求高的问题,提出一种基于改进 YOLOv11n 的光伏板缺陷检测算法,在主干网络的特征提取模块,在 SPPF 模块中,借鉴 LDEConv 结合模型轻量化与细节特征强化思想的卷积结构,融合 LSKA 机制增强感受野,显著增强对小目标特征的捕获能力;其次,FPN 模块借鉴 CGFM 上下文信息的提取与融合机制,设计 ESCM 融合架构,融入 ECA 通道注意力机制,结合共享参数卷积降低冗余计算,避免重复学习,减少参数量,提高多尺度特征融合中上下文信息的自适应调整;在头部网络部分,设计轻量化检测头,通过使用共享卷积减少模型的参数量,确保在不同的感受野范围内能够检测到不同大小的目标。实验结果表明,与 YOLOv11n 模型相比,计算量降低了 6.25%,精度提升 4.5%,平均精度提升了 2.3%,尽管改进算法已取得显著成效,未来仍可进一步集成至移动终端,实现现场实时监测与缺陷识别,为光伏组件的质量控制与运维提供高效技术支持,具有推动光伏产业可持续发展的应用前景。

参考文献

[1] 肖佳,梅琦,黄晓琪,等.“双碳”目标下我国光伏发电技术现状与发展趋势[J]. 天然气技术与经济,2022,

16(5):64-69.

XIAO J, MEI Q, HUANG X Q, et al. Current status and development trends of photovoltaic power generation technology in china under the "dual carbon" goals[J]. Natural Gas Technology and Economy, 2022, 16(5):64-69.

[2] 李明东,李婧雯.“双碳”目标下中国分布式光伏发电的发展现状和展望[J]. 太阳能,2023(5):5-10.

LI M D, LI J W. Development status and prospects of distributed photovoltaic power generation in China under the "dual-carbon" goals[J]. Solar Energy, 2023(5): 5-10.

[3] ZHAO ZH Q, ZHENG P, XU SH T, et al. Object detection with deep learning: A review[C]. IEEE Transactions on Neural Networks and Learning Systems, 2019,30(11): 3212-3232.

[4] 赵强,刘胜杰,韩东成,等.基于改进 K 均值聚类的光伏板缺陷检测方法[J]. 红外技术,2024,46(4):475-482.

ZHAO Q, LIU SH J, HAN D CH, et al. Photovoltaic panel defect detection method based on improved K-means clustering[J]. Infrared Technology, 2024, 46(4): 475-482.

[5] ET-TALEBY A, CHAIBI Y, BOUSSETTA M, et al. A novel fault detection technique for PV systems based

- on the K means algorithm, coded wireless orthogonal frequency division multiplexing and thermal image processing techniques [J]. *Solar Energy*, 2022, 237: 365-376.
- [6] 钟泳松, 徐凌桦, 周克. 基于改进 SSD 算法的光伏组件缺陷检测研究[J]. *微处理机*, 2022, 43(1): 22-25.
ZHONG Y S, XU L H, ZHOU K. Photovoltaic module defect detection based on improved SSD algorithm[J]. *Microprocessors*, 2022, 43(1): 22-25.
- [7] 季瑞瑞, 梅远, 杨思凡, 等. 基于改进 Faster R-CNN 的光伏组件红外热斑检测算法[J]. *激光与红外*, 2024, 54(4): 584-592.
JI R R, MEI Y, YANG S F, et al. Infrared hotspot detection algorithm for photovoltaic modules based on improved Faster R-CNN[J]. *Laser & Infrared*, 2024, 54(4): 584-592.
- [8] 赵晓雨, 高林, 杨校李, 等. 融合注意力机制的 YOLOv5 光伏板电致发光图像缺陷检测算法[J]. *湖北民族大学学报(自然科学版)*, 2023, 41(1): 65-70.
ZHAO X Y, GAO L, YANG X L, et al. Algorithm of YOLOv5 fusing attention mechanism for defect detection of photovoltaic panel electroluminescent image[J]. *Journal of Hubei Minzu University(Natural Science Edition)*, 2023, 41(1): 65-70.
- [9] ZHANG J L, YANG W, CHEN Y, et al. Fast object detection of anomaly photovoltaic (PV) cells using deep neural networks [J]. *Applied Energy*, 2024, 372: 123759.
- [10] 李冰, 赵宽, 白云山, 等. 融合注意力的多尺度光伏板缺陷检测方法[J]. *电力科学与工程*, 2023, 39(8): 1-10.
LI B, ZHAO K, BAI Y SH, et al. Multi-scale photovoltaic panel defect detection method with integrated attention mechanism [J]. *Electric Power Science and Engineering*, 2023, 39(8): 1-10.
- [11] 张文强, 李加树, 宣洋, 等. 基于多尺度融合和改进 YOLOv8n 的光伏缺陷检测方法[J]. *综合智慧能源*, 2024, 46(11): 29-37.
ZHANG W Q, LI J SH, XUAN Y, et al. Photovoltaic defect detection method based on multi-scale fusion and improved YOLOv8n[J]. *Integrated Smart Energy*, 2024, 46(11): 29-37.
- [12] 韩涛, 于帅帅, 马玲, 等. 基于改进 YOLOv11n 的光伏板异物与缺陷检测模型研究[J]. *计算机工程与应用*, 2025, 61(14): 123-134.
HAN T, YU SH SH, MA L, et al. Photovoltaic panel foreign-object and defect detection model based on improved YOLOv11n[J]. *Computer Engineering and Applications*, 2025, 61(14): 123-134.
- [13] 王海群, 陈晓宇, 于海峰. 基于改进 YOLOv10n 的滚动轴承表面缺陷检测[J]. *电子测量技术*, 2025, 48(23): 204-214.
WANG H Q, CHEN X Y, YU H F. Surface defect detection of rolling bearings based on improved YOLOv10n[J]. *Electronic Measurement Technology*, 2025, 48(23): 204-214.
- [14] 郭克友, 韦彩丽, 秦煌城, 等. 基于金字塔分离卷积注意力的路面缺陷检测算法[J]. *交通工程*, 2025, 25(5): 29-37.
GUO K Y, WEI C L, QIN H CH, et al. Pavement defect detection algorithm based on pyramid separable convolution attention [J]. *Journal of Traffic Engineering*, 2025, 25(5): 29-37.
- [15] 陈子轩, 何泽伟, 卢哲明, 等. DEA-Net: 基于细节增强卷积和内容引导注意力机制的单幅图像去雾[J]. *图像处理学报*, 2024, 33: 1002-1015.
CHEN Z X, HE Z W, LU ZH M, et al. DEA-Net: Single-image dehazing based on detail-enhanced convolution and content-guided attention mechanism [J]. *Journal of Image Processing*, 2024, 33: 1002-1015.
- [16] YAN CH M, LI H L. CAPNet: Tomato leaf disease detection network based on adaptive feature fusion and convolutional enhancement [J]. *Multimedia Systems*, 2025, 31(3): 178.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [18] 马添翼, 姜大帅, 朱东, 等. 基于多尺度感知损失与注意力的脑图像配准[J]. *电子测量技术*, 2025, 48(15): 27-34.
MA T Y, JIANG D SH, ZHU D, et al. Brain image registration based on multi-scale perceptual loss and attention [J]. *Electronic Measurement Technology*, 2025, 48(15): 27-34.
- [19] 周翔, 王可庆, 周新翔, 等. 基于改进 YOLOv10n 的电动车头盔佩戴检测算法[J]. *电子测量技术*, 2025, 48(5): 40-49.
ZHOU X, WANG K Q, ZHOU X X, et al. Electric vehicle helmet-wearing detection algorithm based on improved YOLOv10n [J]. *Electronic Measurement Technology*, 2025, 48(5): 40-49.
- [20] 苏国用, 帅洪铎, 邓海顺, 等. 基于机器视觉的煤矿多场景关键目标检测方法研究[J]. *电子测量与仪器学报*, 2025, 39(7): 212-226.
SU G Y, SHUAI H X, DENG H SH, et al. Research on key object detection in multiple coal-mine scenarios based on machine vision [J]. *Journal of Electronic*

- Measurement and Instrumentation, 2025, 39(7): 212-226.
- [21] ZHANG J R, CHEN ZH H, YANG G X, et al. Faster and lightweight: An improved YOLOv5 object detector for remote sensing images [J]. Remote Sensing, 2023, 15(20): 4974.
- [22] 崔建伟,王月明. 基于 YOLOv11 的光伏板缺陷检测与定位系统[J]. 电子测量技术, 2026, 49(5): 77-84.
- CUI J W, WANG Y M. Photovoltaic panel defect detection and localization system based on YOLOv11[J]. Electronic Measurement Technology, 2026, 49(5): 77-84.
- [23] 杨思念, 曹立佳, 郭川东, 等. 基于 PXD-YOLO11s 的陶瓷电路板缺陷检测方法研究[J]. 仪器仪表学报, 2025, 46(7): 307-318.
- YANG S N, CAO L J, GUO CH D, et al. Research on defect detection method of ceramic circuit boards based on PXD-YOLO11s [J]. Chinese Journal of Scientific Instrument, 2025, 46(7): 307-318.

作者简介

张天(通信作者), 博士, 讲师, 主要研究方向为数字化制造及检测技术、智能运维和寿命预测技术。

E-mail: zhangtian@sjzu.edu.cn

崔博文, 硕士研究生, 主要研究方向为数字化检测与智能运维。

E-mail: c0103172023@163.com

崔鑫森, 硕士研究生, 主要研究方向为数字化检测与智能运维。

E-mail: 18004126805@163.com