

DOI: 10.13382/j.jemi.B2407948

基于 YOLO-RMFP 的光伏板缺陷检测方法研究 *

李 莹 孙钰鑫 张 强 王淦源

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要:针对光伏板内部缺陷目标小且尺寸差异大的问题,提出了一种基于 YOLOv8n 的改进模型 YOLO-RMFP。首先,将高效多尺度注意力机制与感受野注意力相结合,提出了一种感受野混合注意力机制,使模型聚焦不同尺度的特征,并解决高效多尺度注意力机制参数共享问题,提升光伏板微小缺陷检测精度。其次,将感受野混合注意力机制与空间金字塔池化模块结合,增强模型对多尺度特征的捕捉能力及对复杂特征区域的关注度,使模型在复杂背景下能够有效剔除噪声并增强鲁棒性,进一步增强光伏板缺陷小目标的检测精度。然后,将 YOLOv8n 主干网络中不同分辨率的特征映射与改进后的多尺度特征融合金字塔网络相结合,进一步增强了特征信息的交互性,以实现更全面的特征提取并增强目标检测的检测性能。最后,在 PIoU 的基础上,通过改变缺陷样本权重,提升目标定位的精确度,有效缓解了光伏板缺陷样本不平衡问题。通过消融实验和对比实验的结果表明,YOLO-RMFP 网络模型的检测精度 mAP@0.5 和 mAP@0.5:0.95 值分别提高 3.1% 和 6.5%,精准度和召回率分别提升了 4.2% 和 3.5%。满足了光伏板缺陷检测的评估要求。

关键词:光伏板缺陷;目标检测;YOLOv8n;感受野混合注意力机制;多尺度特征融合金字塔网络

中图分类号: TM914.4;TN919.5 **文献标识码:** A **国家标准学科分类代码:** 520.20

Research on photovoltaic panel defect detection method based on YOLO-RMFP

Li Ying Sun Yuxin Zhang Qiang Wang Ganyuan

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: To address the challenge of small and highly variable defect sizes in photovoltaic panels, an improved YOLOv8n-based model named YOLO-RMFP is proposed. First, by integrating an efficient multi-scale attention mechanism with receptive field attention, a Receptive Field Mixed Attention mechanism is introduced. This mechanism enables the model to focus on features at multiple scales while addressing the parameter-sharing limitations of conventional multi-scale attention, thereby enhancing the detection accuracy for tiny defects in photovoltaic panels. Second, the Receptive Field Mixed Attention mechanism is integrated with the Spatial Pyramid Pooling module to enhance the model's capability to capture multi-scale features and focus on complex regions. This integration improves the model's ability to suppress noise in complex backgrounds, thereby further boosting the detection precision of small defects in photovoltaic panels. Then, feature maps of different resolutions from the YOLOv8n backbone are fused with an improved multi-scale feature fusion pyramid network. This enhances the interaction of feature information, enabling more comprehensive feature extraction and improving overall detection performance. Finally, based on the PIOUS loss function, the model adjusts the weightings of defect samples according to their detection difficulty. This improves the localization accuracy and effectively mitigates the problem of sample imbalance in photovoltaic defect detection. Results from ablation and comparative experiments show that the YOLO-RMFP model improves detection accuracy, with mAP@0.5 and mAP@0.5:0.95 increasing by 3.1% and 6.5%, respectively. Precision and recall are also enhanced by 4.2% and 3.5%, respectively. These results demonstrate that the proposed model meets the performance requirements for photovoltaic panel defect detection.

收稿日期: 2024-11-08 Received Date: 2024-11-08

* 基金项目:国家自然科学基金(62203197)、辽宁省博士科研启动基金支持项目(2022-BS-330)、葫芦岛市科技项目(2024JH(2)2/11b)、校级科研项目:博士启动基金(21-1036)、2025 年大学生创新创业训练计划(202510147015)、辽宁省教育厅项目(LJ232510147002)资助

Keywords: photovoltaic panel defects; target detection; YOLOv8n; receptive field mixed attention mechanism; multi-scale feature fusion pyramid network

0 引言

随着全球对清洁能源重视程度的不断提升,各国纷纷加大太阳能、风能等可再生能源的开发和利用力度。其中,光伏发电作为关键性技术,近年来迎来了飞速发展的态势。截至 2023 年,光伏发电成为中国仅次于火电的第二大电力来源^[1]。随着光伏发电的广泛应用,光伏板会因制造时的工艺瑕疵、材料质量,以及在长期运行中遭受的环境影响和老化作用^[2]等问题,出现裂纹、黑斑和断栅等缺陷。这些缺陷不仅降低了光伏系统的发电效率和使用寿命,还可能引发设备故障。因此,实现对光伏板缺陷的高精度检测对确保光伏系统的稳定运行并延长设备寿命至关重要。

目前,光伏板缺陷检测方法主要分为两类:传统检测方法和结合深度学习的现代检测方法。传统方法包括人工检测和无损检测。其中,人工检测主要依赖视觉判断,该方法容易受到主观因素的影响,导致误差,并且耗时费力、效率低下,容易出现漏检和误检,从而影响光伏板的发电质量^[3]。而无损检测则通过电磁、声学、光学和热成像等技术,实现快速准确的缺陷检测^[4],其中电致发光检测是最常用的技术。该方法利用半导体材料在通电时释放能量的特性,使产生的红外光能够被红外摄像机捕捉,进而用于缺陷识别^[5]。然而,随着光伏产业的快速发展,传统方法在处理海量数据时面临效率和准确性的挑战。

随着深度学习与计算机视觉技术的不断革新,基于计算机视觉技术和深度学习的现代目标检测算法展现出了高精度、高速度、强鲁棒性和低误检率等优点,克服了传统方法的不足。在现代目标检测方法中,深度学习目标检测算法主要分为一阶段算法和二阶段算法两类。其中,二阶段算法主要以 Faster R-CNN^[6] 和 Mask R-CNN^[7] 模型为代表。二阶段算法首先生成候选区域,然后对这些区域进行精细处理,最终获取缺陷检测信息。由于采用分步处理的方法,二阶段算法通常具有较高的检测精度,但速度相对较慢。Li 等^[8] 开发了一种增强的 Faster R-CNN 模型,该模型利用双向特征融合模块(bidirectional feature pyramid network, BiFPN),巧妙融合了高级特征的丰富语义与低级特征的精确位置信息,成功提取了光伏板上的多尺度缺陷特征,从而有效应对了缺陷区域尺寸差异大的挑战。

一阶段算法最具有代表性的是 YOLO 模型^[9]。YOLO 模型能够直接将输入图像中的目标对象映射到其对应的边界框,并同时预测出这些目标的类别概率,因此

YOLO 模型相比二阶段检测算法具有较高的检测速度,但是稳定性较差。因此 Mazen 等^[10] 在 YOLOv5 基础上引入全局注意力模块(global attention module, GAM)和自适应特征空间融合(adaptively spatial feature fusion, ASFF)以优化特征融合,并在 DIoU 中采用距离交叉聚合,生成更精确的边界框,使平均精度均值(mAP)达到 76.3%。Yin 等^[11] 用渐近特征金字塔网络(asymptotic feature pyramid network, AFPN)替代 YOLOv7 骨干网络,支持非相邻层直接交互,避免大语义差距。同时,他们针对密集目标遮挡问题引入排斥损失函数以减少误检,并提出配备高效多尺度注意力机制(efficient multi-scale attention, EMA)的定制卷积块,显著增强模型感知与表达能力,从而提升了光伏板缺陷检测效果。Meng 等^[12] 提出了 YOLO-PV 目标检测算法,通过削弱 YOLO 中 Backbone 提取深层信息的能力,专注于低级缺陷信息,并在 Neck 部分使用路径聚合网络(path aggregation network, PAN)进行特征融合,显著提高了光伏板缺陷检测的检测精度和速度。

本文研究了光伏板电致光缺陷检测中存在的目标过小、尺寸差异大以及背景复杂等问题。以 YOLOv8n^[13] 网络模型作为基础,通过融合 EMA^[14] 机制与感受野注意力机制(receptive-field attention, RFA)^[15],设计了感受野混合注意力机制(receptive-field mixed attention, RFMA),并将其融入金字塔池化(spatial pyramid pooling-fast, SPPF)^[16] 中。该模块通过动态调整区域权重和扩展感受野,增强模型对细小且难以区分的光伏板缺陷的敏感性的同时,有效缓解复杂背景干扰,确保了光伏板缺陷检测的准确识别。此外,为提高光伏板缺陷检测中的浅层和深层特征融合能力,减少细小缺陷在不同尺度上的信息丢失问题,改进了多分支辅助特征金字塔网络(multi-branch auxiliary feature pyramid network, MBA-FPN)^[17] 并设计了多尺度特征融合金字塔网络(multi-scale feature fusion pyramid network, MSF-FPN)。最后,为进一步提升光伏板检测精度和鲁棒性,减少光伏板缺陷检测中的定位误差,解决光伏板缺陷中难易样本不平衡的问题,结合 PIoU^[18] 与 Focaler-IoU^[19],设计了 Focaler-PIoU,从而实现了高精度的光伏板电致光缺陷检测任务。

1 YOLO-RMFP 网络架构设计

改进后的 YOLO-RMFP 网络模型结构如图 1 所示。首先,将 YOLOv8n 中的 SPPF 模块替换为引入 RFMA 注意力机制的 SPPRFMA 模块,增强了网络的多尺度特征

提取能力,扩展了特征图的感受野,使模型在光伏板电致光检测任务中能够更有效地处理不同尺寸的目标。接着,通过 MSF-FPN 融合各层级的特征信息,进一步提高模型对光伏板缺陷检测任务中不同大小目标的识别精

度。最后,将 YOLOv8n 中的 CIoU^[20]换成改进的 Focaler-PIoU,优化了 YOLO-RMFP 的资源分配和目标定位性能,提升模型对光伏板缺陷检测中小目标缺陷的检测能力。

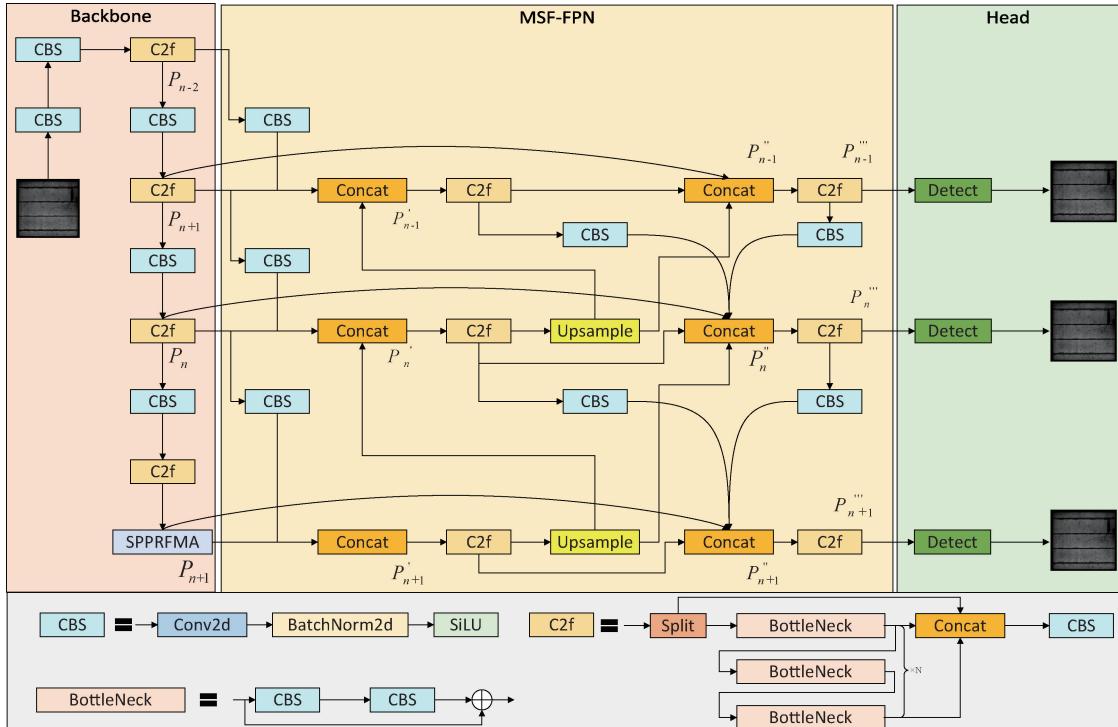


图 1 YOLO-RMFP 网络模型结构

Fig. 1 YOLO-RMFP network model structure

2 改进模块设计与实现

2.1 RFMA 模块

一方面,光伏板缺陷,如微裂纹和隐裂,具有细小难以识别的特点,导致传统检测方法容易发生漏检或误判。另一方面,光伏板表面受环境光照变化、反射和背景噪声的影响,传统检测模型在复杂背景下难以准确区分缺陷与非缺陷区域,从而降低了检测的鲁棒性和精度。为解决以上问题,本文引入 EMA 注意力机制。该机制通过动态调整特征图中不同区域的权重,增强了对微小缺陷的敏感性,准确地捕捉在多变的光照和复杂环境条件下光伏板缺陷,显著提高检测精度和鲁棒性。然而,EMA 在处理动态场景时面临着参数共享问题,这限制了模型在多尺度特征处理中的表现。此外,EMA 的单一结构也制约了不同空间特征之间的有效交互。为克服这些局限性,本文创新性地将 EMA 注意力机制与 RFA 机制融合,提出了 RFMA 注意力机制。RFMA 模块不仅能帮助模型重点关注重要特征区域,还能增强不同空间特征间的交

互,并自适应地调节感受野的大小,从而更精确地捕捉多尺度特征,进一步提升了光伏板电致光缺陷检测的检测精度与鲁棒性。

RFMA 网络结构如图 2 所示。RFMA 首先采用分组卷积、归一化、特征分组操作,将输入特征转化为 $X = [X_0, X_1, \dots, X_{(G-1)}]$, $X_i \in R^{(C//G \times K \times K)}$ 。这种转化优化了感受野调制,使得模型能够灵活调整感受野,从而精准捕捉不同尺度的特征。然后将输出通过双路径的 1×1 分支和单路径的 3×3 分支。在 1×1 分支中,先对输入使用一维最大池化对水平和垂直两个维度方向进行通道编码。以水平维度方向为例,其本质可以视为沿垂直维度方向的位置信息集合,因此水平方向的一维最大池化公式如式(1)所示。然后,将两个编码结果拼接后,通过同一个 1×1 卷积分解为两个向量并在每条路径上依次应用 Sigmoid 激活函数和 1×1 卷积对向量进一步处理。最后通过相乘的方式将两条平行路径的输出与原始输入进行聚合,由此得到 1×1 分支输出。在 3×3 分支中,通过对输入使用 3×3 卷积,来获取多尺度特征表示。

$$z_c^H(H) = \max_0^{K^W} x_c(H, i) \quad (1)$$

随后 1×1 分支和 3×3 分支的输出进入跨空间学习

阶段。首先将 1×1 分支和 3×3 分支的输出转化为二维最大池化的维度形状, 其中 1×1 分支的结果是为 $R_1^{(1 \times //G)} \times R_3^{(C//G \times KH \times KW)}$, 而 3×3 分支的结果为 $R_3^{(1 \times //G)} \times R_1^{(C//G \times KH \times KW)}$ 。接着对调整后的输出进行二维最大池化并通过非线性 Softmax 函数对二维最大池化结果拟合, 从而提取出关键特征, 其中二维最大池化公式如式(2)所示。随后, 通过 Matmul 矩阵乘法, 将两个分支的输出特征映射生成两个空间注意力权重值集合。这两个权重值集合相加后, 经过 Sigmoid 函数得到最终的输出特征图。

最后, 该特征图与分组卷积后的输出进行逐元素相乘, 再经过一次卷积操作, 得出 RFMA 的最终输出结果。

$$z_e = \max_j^K \max_i^K x_e(i, j) \quad (2)$$

综上所述, RFMA 模块通过有效整合不同尺度的特征信息, 自适应调整感受野, 并选择性地强调复杂特征区域, 从而显著增强了模型在光伏板缺陷检测中的多尺度特征融合能力。这一机制使得模型能够在复杂背景下, 精准识别光伏板缺陷检测中细小且难以区分的缺陷, 如微裂纹和隐裂, 提升了检测的精度和鲁棒性。

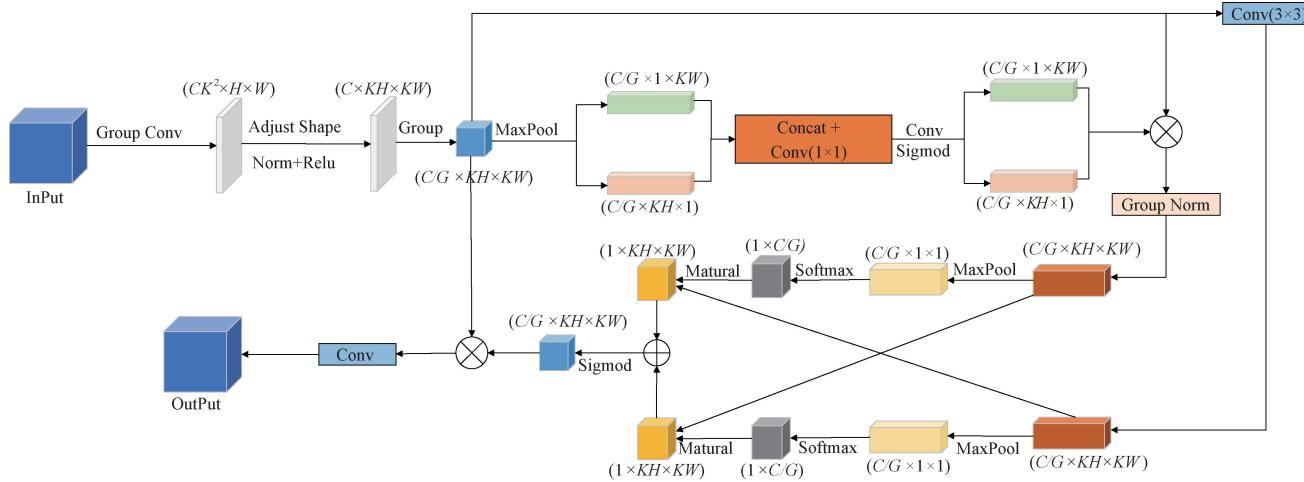


图 2 RFMA 网络结构

Fig. 2 RFMA network structure

2.2 SPPRFMA 模块

在 YOLOv8n 模型中, SPPF 模块通过多尺度池化技术, 能够在不同尺度上精确且高效地提取丰富的特征信息, 并显著增强了全局上下文信息的捕捉能力, 这对于提高模型在复杂多变环境下的目标检测精度至关重要。为了进一步提升 SPPF 模块在光伏板电致光缺陷检测中的检测性能, 本文在 SPPF 模块基础上巧妙地通过残差连接融入了 RFMA 模块, 创新性地设计了基于感受野混合注意力机制的空间金字塔池化(spatial pyramid pooling based on receptive field mixed attention, SPPRFMA)模块, 模块网络结构如图 3 所示。SPPRFMA 模块有效增强了模型在多尺度特征提取中的能力, 尤其在处理光伏板缺陷时, 能够更精确地识别和提取复杂特征。令模型在面对细小且难以辨识的缺陷, 如微裂纹和隐裂时, 能够提供更高的检测精度。通过引入动态感受野调整和权重分配机制, SPPRFMA 模块能够高效地剔除光伏板缺陷检测中复杂背景的噪声和无关信息, 使模型专注于裂纹、隐裂等细微缺陷。优化后的特征融合方法不仅提升了模型在复杂背景下的鲁棒性, 还增强了模型对不同类型缺陷的适应能力, 从而显著提高了光伏板缺陷检测的准确性和稳定性。

2.3 MSF-FPN

在深度学习模型的目标检测中, 浅层网络主要负责处理图像的精细边缘和局部细节, 从而提升目标的精确定位; 而深层网络则侧重于提取高层语义特征, 帮助模型更好地捕捉全局上下文信息, 理解目标的整体轮廓和类别。为了充分整合不同层次的特征优势, 特征金字塔网络应运而生, 并通过跨尺度的特征融合机制显著提升了多目标检测的能力。然而, 传统 FPN 采用的自上而下和自下而上的线性融合策略, 在光伏板缺陷检测任务中存在一定局限性。光伏板缺陷通常具有多尺度、形态各异的特征, 且容易受到成像环境的影响。传统融合策略既

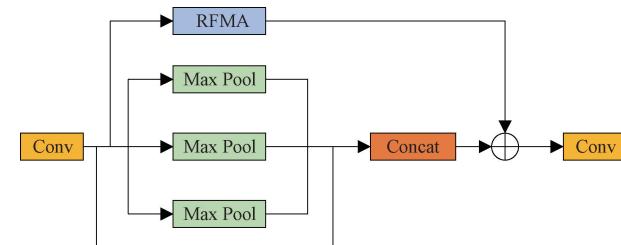


图 3 SPPRFMA 网络结构

Fig. 3 SPPRFMA network structure

无法充分保留浅层网络对微小缺陷的敏感性,也无法有效利用深层网络在处理复杂缺陷时的语义理解能力。这种特征融合的不足直接导致了模型在检测精度和鲁棒性方面的欠佳,特别是在微裂纹、隐裂等细小缺陷的检测中,常常出现特征信息丢失或误判,严重影响检测结果的可靠性。针对这一问题,本文改进了 MBA-FPN,并设计了 MSF-FPN。传统特征金字塔结构、MSF-FPN 的网络结构如图 4、5 所示。

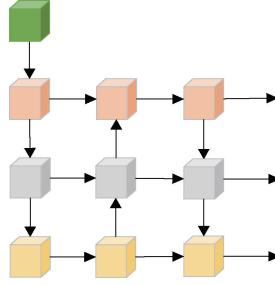


图 4 传统特征金字塔网络结构

Fig. 4 Traditional feature pyramid network structure

MSF-FPN 主要包括浅层辅助融合和深层辅助融合两个部分。浅层辅助融合将主干网络的同层特征、浅层高分辨率细节与深层语义信息进行跨层级融合。这种融合方式在保留微小缺陷精准定位能力的同时,显著提升了模型的空间表征能力,有效解决了 YOLOv8n 在光伏板缺陷检测中因低对比度干扰和特征表达单一化而导致的定位偏差问题,从而提高了光伏板缺陷检测的准确性和目标定位的精确度。浅层辅助融合公式如式(3)所示。其中, $P_{n+1}, P_n, P_{n-1} \in R^{(H \times W \times C)}$ 为主干网络中不同分辨率的特征映射、符号 $U(\cdot)$ 表示上采样、 $C2F(\cdot)$ 表示 $C2F$ 、 $C(\cdot)$ 表示使用卷积下采样。

$$\begin{cases} P'_{n+1} = \text{Concat}(P_{n+1}, C(P_n)) \\ P'_n = \text{Concat}(P_n, C(P_{n-1}), U(C2F(P'_{n+1}))) \\ P'_{n-1} = \text{Concat}(P_{n-1}, C(P_{n-2}), U(C2F(P'_n))) \end{cases} \quad (3)$$

深度辅助融合通过跨层梯度密集连接机制,驱动不同层级的梯度信息与特征图进行深度交互,强化特征金字塔的多尺度语义融合能力。该设计利用梯度流的连续性引导检测头捕获多样化的上下文信息,有效提升了光伏板缺陷检测不同缺陷共存时的特征区分度,并弥补了传统特征融合方法因信息偏差导致的多尺度缺陷漏检问题。深度辅助融合公式如式(4)所示。其中,高分辨率特征融合层为 P''_{n+1} 、浅层分辨率特征融合层为 P'_{n-1} 、同级别特征融合层为 P'_n 、同级主干特征映射为 P_n 、前一层特征信息增强结果为 P''_{n-1} 。

$$\begin{cases} P''_{n-1} = \text{Concat}(P_{n-1}, C2F(P'_{n-1}), U(C2F(P'_n))) \\ P'_n = \text{Concat}(C(C2F(P'_{n-1})), C(C2F(P''_{n-1})), \\ P_n, C2F(P'_n), U(C2F(P'_{n+1}))) \\ P''_{n+1} = \text{Concat}(C(C2F(P'_n)), C(C2F(P''_n)), \\ P_{n+1}, C2F(P'_{n+1})) \end{cases} \quad (4)$$

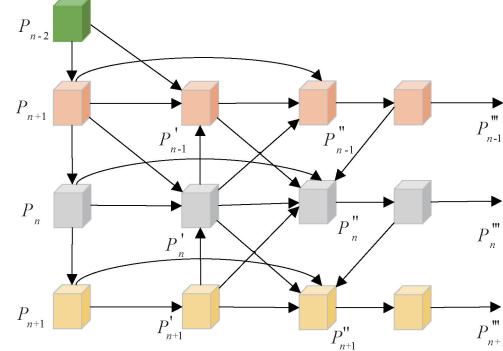


图 5 MSF-FPN 网络结构

Fig. 5 MSF-FPN network structure

综上所述,MSF-FPN 通过浅层辅助融合和深度辅助融合,既保留了丰富的定位细节,又增强了空间表征能力,同时提升了特征信息的交互性。这一创新架构成功解决了传统模型在光伏板缺陷检测中存在的多尺度特征融合不足、细节信息丢失等关键问题,从而大幅提高了检测精度和模型鲁棒性。

3 损失函数改进

3.1 Focaler-PIoU

为了提高光伏板电致光缺陷检测的定位精度和鲁棒性,本文将传统的 CIoU 损失函数替换为 PIoU 损失函数,并引入 Focaler-IoU 的思想,设计了 Focaler-PIoU 损失函数。PIoU 损失函数通过像素级别的 IoU 计算,能够更准确地衡量定向边界框的重叠度,特别适用于高纵横比和复杂背景下的目标检测任务。Focaler-IoU 则通过线性区间映射的方式,调整不同回归样本的关注度,解决了样本难易分布不均的问题。将两者结合,Focaler-PIoU 损失函数能够在优化边界框回归的同时,增强对难样本的关注,提高模型在复杂环境下的检测性能。

PIoU 通过提出一个自适应的惩罚因子 P ,动态调整边界框的回归路径。惩罚因子 P 的公式如式(5)所示。

$$P = (\frac{d_{w_1}}{w_{gt}} + \frac{d_{w_2}}{w_{gt}} + \frac{d_{h_1}}{h_{gt}} + \frac{d_{h_2}}{h_{gt}})/4 \quad (5)$$

式中: $d_{w_1}, d_{w_2}, d_{h_1}, d_{h_2}$ 分别表示预测框与目标框对应边之间距离的绝对值; w_{gt} 和 h_{gt} 表示目标框的高度和宽度。

由于惩罚因子 P 的分母仅取决于目标框的大小,而与锚框和目标框的最小外接框无关,因此,在损失函数使用惩罚因子 P 不会导致锚框扩展。基于罚因子 P ,进一步提出了适用于边界框回归的惩罚函数,其公式如式(6)~(8)所示。该函数能够根据锚框自适应生成相应的梯度,从而降低低质量锚框的影响、加速中等质量锚框的回归速度、稳定高质量锚框的优化过程,并优化资源分配,从而提高了模型对光伏板缺陷检测的整体检测精度。

$$f(x) = 1 - e^{-x^2} \quad (6)$$

$$PIoU = IoU - f(P), -1 \leqslant PIoU \leqslant 1 \quad (7)$$

$$L_{PloU} = 1 - PIoU = L_{IoU} + f(p), 0 \leqslant L_{PloU} \leqslant 2 \quad (8)$$

随后,在 $PIoU$ 的基础上,通过引入 Focaler-IoU 思想调整光伏板缺陷样本的难易权重,使模型更加聚焦于光伏板的复杂缺陷,从而提高检测精度。Focaler-IoU 公式如式(9)所示,其中, $[d, u] \in [0, 1]$ 。通过调整 d 和 u 的数值,模型对困难样本赋予更高权重,同时降低易检测样本的损失权重,从而使模型在训练时更专注于困难样本。因此 Focaler-PIoU 通过线性区间映射方法将 $IoU^{focaler}$ 融合到 $PIoU$ 中,以提升目标检测中的误差回归效果,从而提高光伏板电致光缺陷检测的整体检测精度。Focaler-PIoU 公式如式(10)所示。

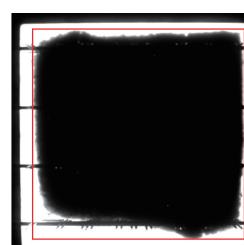
$$IoU^{focaler} = \begin{cases} 0, & IoU < d \\ \frac{IoU - d}{u - d}, & d \ll IoU \ll U \\ 1, & IoU > u \end{cases} \quad (9)$$

$$L_{Focaler-PIoU} = L_{PloU} + IoU - IoU^{focaler} \quad (10)$$

综上所述, Focaler-PIoU 在 $PIoU$ 的基础上引入 $IoU^{focaler}$,使得模型在高效处理边界框回归任务的同时,能够给予小目标和难以检测的目标更多关注。这一改进不仅显著增强了模型对复杂样本的检测能力,提升了检测精度,还减少了简易样本对训练过程的干扰,提升了光伏板电致光缺陷检测的整体性能。



(a) 裂纹
(a) Crack



(b) 黑芯
(b) Black core



(c) 断栅
(c) Finger



(d) 粗线
(d) Thick line

图 6 数据集缺陷类型

Fig. 6 Dataset defect types

4 实验结果与分析

4.1 实验配置

本文实验在 Pytorch2.1.0+CUDA12.5 深度学习框架进行实验,实验的软件和硬件参见表 1 所示。本文实验采用的实验参数如表 2 所示。

表 1 软件和硬件参数

Table 1 Software and hardware parameters

名称	参数
操作系统	Windows11
GPU	NVIDIA GeForce RTX 3070 Ti
处理器	12th Gen Intel(R) Core(TM) i9-12900H 2.50 GHz
内存	32 GB
Python	3.9.1

表 2 实验参数

Table 2 Experimental parameters

参数名称	参数设置
Epochs	150
Batchsize	2
imgsz	640
lr_0	0.01
lr_f	0.01

4.2 数据集预处理

实验使用的是自建的光伏板内部缺陷数据集,数据由红外摄像机拍摄,涵盖 4 种缺陷类型:裂纹、黑芯、断栅和粗线。初始数据集共包含 782 张图像,如图 6 所示。为增加样本数量,本文通过旋转、添加噪声等数据增强方法将数据集扩展至 3 150 张。实验中,将数据集按 8:1:1 的比例随机划分为训练集、测试集和验证集,分别为 2 520、315 和 315 张。

4.3 评价指标

为验证本文提出的算法在光伏板缺陷检测的可行性。实验结果主要以 mAP@0.5 作为检测指标。mAP@0.5 指的是阈值在 0.5 以上的平均检测精度均值。mAP 的计算公式如下:

$$mAP = \frac{\sum_{n=1}^{Num(class)} AP(n)}{TP + TN + FP + FN} \quad (11)$$

$$AP = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

式中: AP 表示平均检测精度; TP 代表目标检测模型中可以正确检测出缺陷的预测框数量; TN 表示负样本数量; FP 为目标检测中检测错误的预框数量; FN 表示未能检测目标的预测框数量。

4.4 对比实验

为验证模型的改进效果, 在相同配置和数据集条件下, 将 YOLO-RMFP 算法与其他常见的目标检测算法进行了对比。本文选择了二阶段目标检测算法 Faster R-CNN、Mask R-CNN, 以及 YOLO 系列的 YOLOv5s、YOLOv7-tiny、YOLOv8n、YOLOv10n 进行对比实验, 结果如图 7 和表 3 所示。由图 7 和表 3 可知, YOLO-RMFP 的 mAP@0.5 达到了 94.2%, 是所有对比模型中平均检测精度最高的, 相较其他模型分别提高了 8.2%、7.6%、7.6%、5.8%、9.5%、3.1% 和 8.5%。尽管 YOLO-RFMP 的帧率达到了 201.4 fps, 略低于某些轻量级模型, 如 YOLOv8n 和 YOLOv5s, 但在精度与推理速度的平衡上展现出了卓越的性能。凭借其适中的计算量, 该模型在性能与效率之间实现了理想的平衡, 非常适合那些既要求高精度又要求高速度的应用场景。综合考虑检测速度和精度两个方面, 本文算法在光伏板缺陷检测中的整体性能最优, 不仅准确率较高, 还能实现实时检测。

4.5 消融实验

为验证 YOLO-RMFP 算法的有效性, 首先对

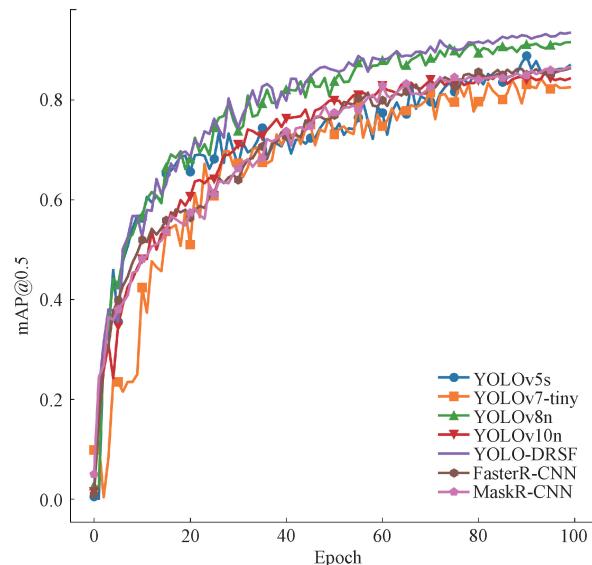


图 7 不同目标检测模型的 mAP@0.5 对比结果

Fig. 7 mAP@0.5 comparison results of different object detection models

表 3 对比实验

Table 3 Comparative experiments

模型	mAP@0.5/%	帧率/fps	计算量/GFLOPS
Faster R-CNN	86.0	52.3	134
Mask R-CNN	86.6	48.1	187
YOLOv5s	88.8	208.1	8.7
YOLOv7-tiny	84.7	103.8	13.2
YOLOv8n	91.1	211.1	8.1
YOLOv10n	85.7	205.7	8.4
YOLO-RFMP	94.2	201.4	9.9

SPPRFMA 模块、MSF-FPN 特征金字塔结构和 Focal-PIoU 损失函数进行了消融实验。通过 mAP、计算量和检测速度等评估指标, 分析各模块在原有模型中的引入对性能的影响, 实验结果如表 4 所示。

表 4 消融实验

Table 4 Ablation experiments

SPPRFMA	MSF-FPN	Focaler-PIou	mAP@0.5/%	mAP@0.5:0.95/%	召回率/%	精度/%	检测速度/fps	计算量/GFLOPS
√	√	√	91.1	62.8	87.3	88.4	211.1	8.1
			91.9	64.9	88.4	88.9	203.4	8.7
			92.3	63.4	88.5	89.0	198.3	9.1
√	√	√	91.4	63.1	91.6	83.9	223.3	8.1
			93.5	65.1	90.7	89.1	194.6	9.9
√	√	√	92.2	64.6	87.5	89.0	205.7	8.7
			92.7	65.3	88.5	87.9	203.5	8.9
√	√	√	94.2	69.3	90.8	92.6	201.4	9.9

当单独启用 SPPRFMA 模块时, 模型的 mAP@0.5 和 mAP@0.5:0.95 分别达到 91.9% 和 64.9%, 召回率提

升至 88.4%, 检测精度小幅上升至 88.9%, 但检测速度下降至 203.4 fps, 计算量增加至 8.7 GFLOPS。这表明,

SPPF 模块结合 RFMA 注意力机制后,增强了模型的特征捕捉能力。单独启用 MSF-FPN 特征金字塔结构时, mAP@0.5 和 mAP@0.5:0.95 分别提升至 92.3% 和 63.4%,召回率和检测精度提升至 88.5% 和 89.0%,但检测速度下降至 198.3 FPS,计算量增加至 9.1 GFLOPS。这表明 MSF-FPN 在特征融合方面效果显著,使模型可以获得更丰富的信息和更强的表达能力。当使用 Focaler-PIoU 损失函数时,mAP@0.5 和 mAP@0.5:0.95 提升至 91.4% 和 63.1%,召回率显著提高至 91.6%,检测速度上升至 223.3 fps,计算量保持不变,但检测精度下降至 83.9%。该结果表明,Focaler-PIoU 模块增强了模型对困难样本的检测能力,削弱了简易样本对模型的影响,但可能会导致模型过度关注困难样本,从而牺牲了简单样本

的准确性,使得模型的检测精度略有下降。

在启用全部模块后,光伏板缺陷检测模型的 mAP@0.5 和 mAP@0.5:0.95 提升了 3.1% 和 6.5%,召回率及检测精度分别提升至 90.8% 与 92.6%,检测速度下降了 9.7 fps,计算量增加了 1.8 GFLOPS。综上所述,虽然 YOLO-RMFP 算法针对光伏板缺陷的检测速度略有下降并增加了一部分计算量,但检测 mAP@0.5、mAP@0.5:0.95 召回率和检测精度显著提升,有效实现了光伏板缺陷检测的实时性和实用性。

4.6 检测结果可视化对比

为了验证 YOLO-RMFP 模型的实际检测效果,随机抽取 4 类光伏板缺陷图片进行检测,同时和初始 YOLOv8n 模型的检测结果进行对比,结果如图 8 所示。

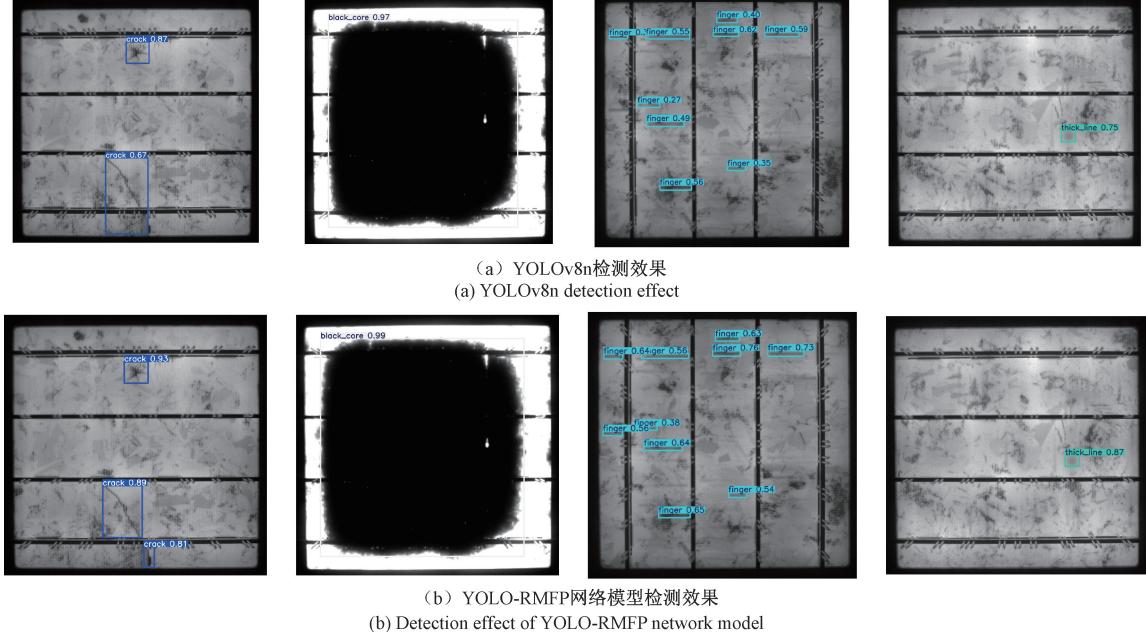


图 8 改进前后检测效果对比

Fig. 8 Comparison of detection results before and after improvement

通过对比两种模型的检测结果,原始模型和 YOLO-RMFP 模型均成功检测出所有裂纹、黑芯和断栅缺陷,未出现漏检情况。然而,在粗线缺陷的检测中,YOLOv8n 模型存在漏检。YOLO-RMFP 模型在裂纹、断栅和粗线 3 类缺陷的检测精度上均优于 YOLOv8n 模型 2%~25%,而在黑芯缺陷的检测精度上,两者表现相当。表明改进后的模型在光伏板电致光缺陷检测中具有更高的精确度和稳定性,尤其在处理复杂或细小缺陷时,能够更好地提升检测性能并减少漏检现象,从而增强了对多种缺陷类型的适应性和鲁棒性。

4.7 鲁棒性测试

受到环境光照不均、设备噪声和表面污染等因素的影响。这些干扰因素会降低图像质量,模糊细节或导致局部区域的遮挡,从而显著增加光伏板缺陷检测的复杂性。因此,检测算法的鲁棒性测试至关重要,以确保其有效性。

在噪声、图像旋转和对比度增强等多种外部干扰条件下,YOLO-RMFP 与 YOLOv8n 在光伏板缺陷检测中的性能对比如图 9 所示。实验结果表明,在复杂环境下,YOLO-RMFP 在光伏板缺陷检测任务中优于 YOLOv8n。在对比度增强、噪声增加、翻转和旋转 90° 等干扰下,YOLO-RMFP 在裂纹缺陷检测中的精度分别比 YOLOv8n 高出 14%、30%、17% 和 2%。而在断栅缺陷检测中,YOLO-RMFP 的性能提升幅度在 10%~30%,且 YOLOv8n

在实际应用中,光伏板的电致光缺陷检测任务通常

出现了漏检现象。YOLO-RMFP 在检测准确性和稳定性方面展现出明显优势,特别是在图像质量受到干扰的情况下,仍能保持较高的缺陷识别精度。这些结果突显了

YOLO-RMFP 在应对复杂环境干扰时的卓越鲁棒性和可靠性,进一步证明了其在挑战性条件下维持高检测准确性的能力。

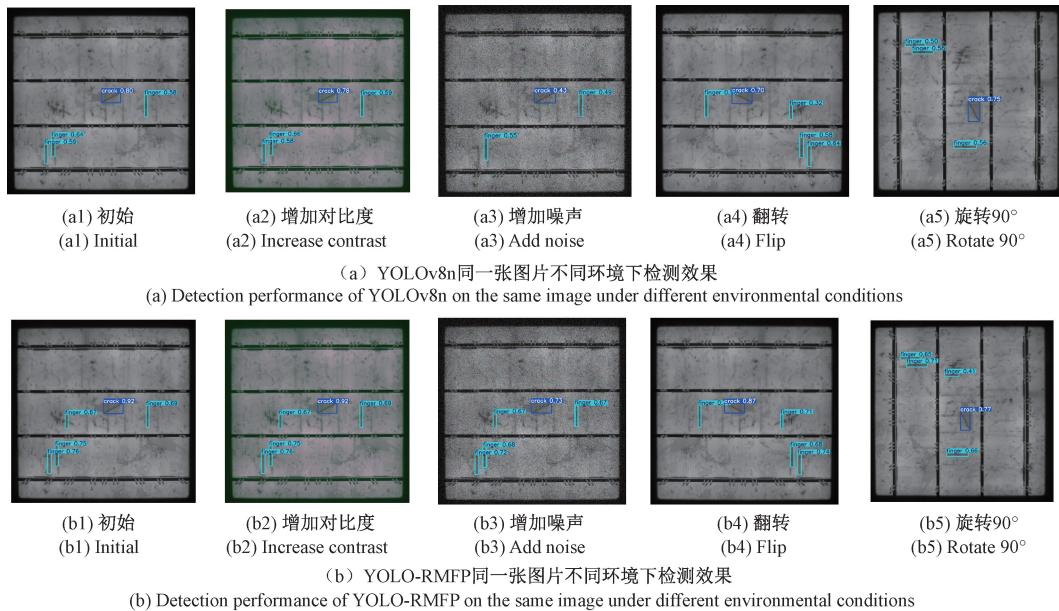


图 9 鲁棒性测试结果对比

Fig. 9 Comparison of robustness testing results

5 结 论

针对光伏板电致光检测中小目标难以捕捉、多尺度特征融合不足及回归定位精度不高所导致的检测精度下降和漏检率增高问题,本文在 YOLOv8n 模型基础上从结构与损失函数两方面进行优化,提出了 YOLO-RMFP 检测模型。在优化结构方面,首先将改进的 RFMA 模块融入 YOLOv8n 模型的 SPPF 模块,增强了光伏板电致光检测小目标和局部特征的特征提取能力,并提升了模型对复杂区域的关注度。随后,在模型的 Neck 部分,采用 MSF-FPN,通过浅层特征辅助深层语义实现多尺度信息的高效融合,解决了光伏板缺陷检测中细节丢失和尺度不匹配问题。针对损失函数方面,最后,在损失函数优化方面,本文用 Focaler-PIoU 替代传统 CIoU,通过优化了光伏板缺陷检测任务中的资源分配和回归过程,提高了模型对光伏板内部缺陷小目标的检测效率和精度。根据实验结果表明,改进后的 YOLO-RMFP 光伏板缺陷检测模型的 mAP@0.5 和 mAP@0.5:0.95 达到了 94.2% 和 69.3%,精准度达到了 92.6%,召回率达到了 90.8%。

尽管该模型在精度和召回率方面取得了良好表现,其检测速度虽满足实际需求,但仍存在进一步优化空间。未来的研究应重点提升模型的推理速度并降低计算复杂

度,以实现更高的实时性与部署灵活性,进一步提升模型在光伏板缺陷检测的实际应用价值。

参 考 文 献

- [1] 王一波,赵颖,汪雷,等. 2023 年中国光伏技术进展综述[J]. 太阳能,2024(7):8-19.
WANG Y B, ZHAO Y, WANG L, et al. Review of China's photovoltaic technology progress in 2023 [J]. Solar, 2024 (7):8-19.
- [2] WANG N, LIU X, ZHOU B, et al. Eddy current O-scan and C-scan imaging techniques for macrocrack detection in silicon solar cells [J]. Nondestructive Testing and Evaluation, 2019, 34(4): 389-400.
- [3] 陈功,蔡磊,张琳,等. 光伏热斑模拟建模及热成像分析[J]. 电子测量与仪器学报,2021,35(8):191-197.
CHEN G, CAI L, ZHANG L, et al. Simulation modeling and thermal imaging analysis of photovoltaic hot-spot effects [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(8): 191-197.
- [4] DU B L, YANG R Z, HE Y Z, 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(6):

1117-1151.

- [5] FUYUKI T, KONDO H, YAMAZAKI T, et al. Photographic surveying of minority carrier diffusion length in polycrystalline silicon solar cells by electroluminescence [J]. Applied Physics Letters, 2005, 86(26): 262108.

- [6] 刘毅,于畅洋,李国燕,等. UAST-RCNN: 遮挡行人的目标检测算法 [J]. 电子测量与仪器学报, 2022, 36(12): 168-175.

LIU Y, YU CH Y, LI G Y, et al. UAST-RCNN: An object detection algorithm for occluded pedestrians [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12): 168-175.

- [7] HE K, GKIOXARI G, DOLLÁR P, et al. Mask r-cnn [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.

- [8] LI T, SUN Y. Defect detection of solar panels using improved faster R-CNN [C]. International Conference on Image, Signal Processing, and Pattern Recognition, 2023, 12707: 605-610.

- [9] 杨阳,杨帅,闫敏,等. 基于UDD-YOLO的边缘端绝缘子放电严重程度评估算法 [J]. 电子测量与仪器学报, 2024, 38(1): 219-227.

YANG Y, YANG SH, YAN M, et al. An edge-end algorithm for assessing the severity of insulator discharge based on UDD-YOLO [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 219-227.

- [10] MAZEN F M A, SEOUD R A A, SHAKER Y O. Deep learning for automatic defect detection in PV modules using electroluminescence images [J]. IEEE Access, 2023, 11: 57783-57795.

- [11] YIN W, LINGXIN S, MAOHUAN L, et al. PV-YOLO: lightweight YOLO for photovoltaic panel fault detection [J]. IEEE Access, 2023, 11: 10966-10976.

- [12] MENG Z, XU S, WANG L, et al. Defect object detection algorithm for electroluminescence image defects of photovoltaic modules based on deep learning [J]. Energy Science & Engineering, 2022, 10(3): 800-813.

- [13] WANG Z, HUA Z, WEN Y, et al. E-YOLO: Recognition of estrus cow based on improved YOLOv8n model [J]. Expert Systems with Applications, 2024, 238: 122212.

- [14] OUYANG D, HE S, ZHANG G, et al. Efficient multi-

scale attention module with cross-spatial learning [C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023: 1-5.

- [15] ZHANG X, LIU C, YANG D, et al. RFACConv: Innovating spatial attention and standard convolutional operation [J]. ArXiv preprint arXiv:2304.03198, 2023.

- [16] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv preprint arXiv:2004.10934, 2020.

- [17] YANG Z, GUAN Q, ZHAO K, et al. Multi-branch auxiliary fusion YOLO with re-parameterization heterogeneous convolutional for accurate object detection [J]. ArXiv preprint arXiv:2407.04381, 2024.

- [18] LIU C, WANG K, LI Q, et al. Powerful-IoU: More straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism [J]. Neural Networks, 2024, 170(2): 276-284.

- [19] ZHANG H, ZHANG S. Focaler-IoU: More focused intersection over union loss [J]. ArXiv preprint arXiv:2401.10525, 2024.

- [20] WU S, LI X, WANG X. IoU-aware single-stage object detector for accurate localization [J]. Image and Vision Computing, 2020, 97: 103911.

作者简介



李莹(通信作者),任职于辽宁工程技术大学电气与控制工程学院,硕士生导师,东北大学博士,主要研究方向为非线性复杂系统建模、智能控制、机器视觉。

E-mail: liying1982ren@163.com

Li Ying(Corresponding author) affiliated with the School of Electrical and Control Engineering at Liaoning Technical University, a Master's Supervisor. She received the Ph. D. from Northeastern University. Her main research focuses on nonlinear complex system modeling, intelligent control, and machine vision.



孙钰鑫,2022年于辽宁工程技术大学获得学士学位。现为辽宁工程技术大学硕士研究生,主要研究方向为机器视觉。

E-mail: 1736045302@qq.com

Sun Yuxin received his B. Sc. degree from Liaoning Technical University in 2022. He is now a M. Sc. candidate at Liaoning Technical University. His main research interest includes machine vision.



张强,毕业于中国东北大学,于 2020 年获得计算机系统结构博士学位。现就职于辽宁工程技术大学软件学院,主要研究方向包括人工智能、操作系统与形式化验证方法。

E-mail: zhangqiang@lntu.edu.cn

Zhang Qiang received his Ph. D. in Computer Architecture from Northeastern University, China, in 2020. He is now with the School of Software, Liaoning Technical University. His research interests include artificial intelligence, operating

systems, and formal verification methods.



王淦源,2024 年于青岛科技大学获得学士学位。现为辽宁工程技术大学硕士研究生,主要研究方向为机器视觉。

E-mail: 2235694110@qq.com

Wang Ganyuan received his B. Sc. degree from Qingdao University of Science and Technology in 2024. He is now a M. Sc. candidate at Liaoning Technical University. His main research interest includes machine vision.