

改进的 YOLOv8n 遥感图像轻量化检测模型^{*}李泽胤^{1,2} 李 栋^{1,2} 房建东^{1,2} 赵 磊^{1,2} 张佳惠^{1,2}(1. 内蒙古工业大学信息工程学院 呼和浩特 010080; 2. 内蒙古工业大学内蒙古感知技术与智能
系统重点实验室 呼和浩特 010080)

摘 要: 针对遥感图像目标排列密集、尺度差异大以及背景复杂造成的检测虚警率高、检测精度低、漏检和误检的问题,提出了一种基于 YOLOv8n 的遥感图像检测算法 YOLOv8-EP。首先,构建特征聚焦扩散金字塔网络(FFDPN),通过并行深度卷积捕获多尺度信息,同时加入扩散机制将特征信息扩散到各个检测尺度增强特征交互。设计轻量化的任务动态调整检测头(TADD),通过特征共享和并行任务处理,提高检测的定位和分类性能。其次,引入 SimAM 注意力机制捕捉图像中关键信息,增加模型感受野。最后,引入 Inner-CIoU 损失函数改善低质量图像对网络梯度的不利影响,加速模型收敛。在 NWPU VHR-10 数据集和 RSOD 数据集上的实验结果表明,YOLOv8-EP 的 mAP 分别达到 97.6% 和 97.9%,参数量下降 13%,相比于 YOLOv8n 基线网络提升了 2.2% 和 1.5%,能够满足工业部署的要求,整体达到良好的检测性能。

关键词: 遥感图像;YOLOv8n;特征交互;任务动态调整检测头

中图分类号: TP751;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improved YOLOv8n lightweight detection model for remote sensing images

Li Zeyin^{1,2} Li Dong^{1,2} Fang Jiandong^{1,2} Zhao Lei^{1,2} Zhang Jiahui^{1,2}

(1. School of Information Engineering, Inner Mongolia Institute of Technology, Huhhot 010080, China; 2. Inner Mongolia Institute of Technology, Inner Mongolia Key Laboratory of Perception Technology and Intelligent System, Huhhot 010080, China)

Abstract: Aiming at the problems of high detection false alarm rate, low detection accuracy, leakage and false detection caused by dense target arrangement, large scale difference and complex background of remote sensing images, a remote sensing image detection algorithm YOLOv8-EP based on YOLOv8n is proposed. Firstly, a feature focus diffusion pyramid network (FFDPN) is constructed to capture multi-scale information through parallel deep convolution, while adding a diffusion mechanism to diffuse the feature information to each detection scale to enhance feature interaction. A lightweight task align dynamic detection head (TADD) is designed to improve the localisation and classification performance of detection through feature sharing and parallel task processing. Then, the SimAM attention mechanism is introduced to capture key information in the image and increase the model sensory field. Finally, the Inner-CIoU loss function is introduced to improve the detrimental effect of low-quality images on the network gradient and accelerate the model convergence. Experimental results on the NWPU VHR-10 dataset and RSOD dataset show that YOLOv8-EP achieves a mAP of 97.6% and 97.9%, respectively, with a 13% decrease in the number of parameters, and improves by 2.2% and 1.5% compared to the YOLOv8n baseline network, which can meet the requirements of industrial deployment and achieve good detection performance overall.

Keywords: remote sensing images; YOLOv8n; feature interaction; task align dynamic detection head

0 引言

遥感图像包含丰富的地物信息,已广泛应用于环境监测、城市规划、地质勘探、地理信息系统(geographic

information system, GIS)更新等领域。随着遥感图像的质量和可获得性的提高,更加准确地从遥感图像中检测目标成为研究的热点。传统的遥感影像目标检测算法分为人工特征建模和基于模板的匹配两种^[1]。这些方法主要通过

遥感图像的光谱、颜色、纹理、形状和空间信息等表达能力较弱的特征完成检测任务,通常是低级密集特征,包含大量冗余信息,鲁棒性和泛化性^[2]较弱,不适合多类别遥感图像目标的检测。因其对复杂场景适应性差、空间特性建模能力弱及高维数据处理能力有限,逐渐被深度学习方法取代。因此在面对日益复杂的遥感场景图像目标检测时,上述方法难以续用。

近年来,在卷积神经网络的基础上产生了 AlexNet^[3]、R-CNN^[4]、Faster R-CNN^[5] 和 Mask R-CNN^[6] 等一系列基于深度学习的检测算法,他们的出现为后来更加全面的网络奠定了理论和实践基础。以 YOLO 系列的一阶段算法不断更新迭代,在长时间内引领目标检测任务的潮流。比如:YOLO-Fine^[7]、SeMo-YOLO^[8]、DAGN^[9] 等,此类算法成功提高了遥感图像的检测精度,但未能有效应对网络精度提升带来的复杂度增加问题。随着遥感技术的不断发展,这些早期模型的局限性日益显现。为了满足遥感图像小目标检测的需求,Li 等^[10] 提出基于改进 YOLO 的遥感图像目标检测方法,在 YOLOv5 网络中增加了一个小目标检测层,提高了检测精度,但在遥感图像这种数据量大、维度高的场景中,模型的计算负担严重影响了其实际应用。Zhang 等^[11] 使用轻量级非对称检测头(lightweight asymmetric detection head, LADH-Head),通过独立处理分类与回归任务实现了轻量化,提升了检测性能,但相较于更新的网络架构,其性能提升有限。随着 YOLOv6^[12]、YOLOv7^[13] 和 YOLOv8^[14] 等新型网络模型的出现,这些模型引入新的网络结构和先进的策略,但是在面对复杂庞大的遥感检测任务时,通常面临以下 3 类问题:

- 1) 网络复杂度与精度提升的平衡问题;
- 2) 小目标与多尺度目标的检测难题;
- 3) 精度与轻量化的矛盾问题。

尽管 YOLOv8 模型因其强大的功能和稳定的检测效果而被广泛应用,但仍面临着若干局限性。以 YOLOv8n 为例,Nie 等^[15] 在 YOLOv8n 网络中引入尺度序列特征融合(scale sequence feature fusion, SSFF)模块和层次分明的金字塔网络(hierarchical pyramid attentive network, HPANet)结构,减少了模型的整体参数,增加更多的梯度路径更加高效的实现特征融合,提高整体遥感图像检测精度。但忽略了小目标尺度的特征提取,导致模型对小目标的检测效果不佳。Wang 等^[16] 在主干网络加入高效多尺度注意力模块(efficient multi-scale attention, EMA),增强了多尺度遥感图像的检测能力,然而对于背景噪声或其他不相关信息的处理能力较弱,容易产生漏检和错检问题。Li 等^[17] 在 YOLOv8 网络中引入卷积块注意力模块(convolutional block attention module, CBAM),提高了网络对局部特征的关注度。但通过为每个位置分配不同的权重,局部关键特征得以突出却难以排除背景干扰,小目标检测效果较差。王子龙等^[18] 利用内容感知特征重组

(content-aware reassembly of features, CARAFE)优化最近邻上采样方法获取更多遥感图像中小目标的特征信息,但增加了网络计算量。这些设计和优化使得它们在特定任务中表现出色,但也限定了它们的应用范围^[19],总而言之,现有的检测模型难以高效地捕捉到图像中不同尺度的特征,不能准确地分类^[20] 和定位图像中的目标,导致检测网络精度降低,产生漏检和错检。在面临高参数量的模型时需要更多的计算资源进行训练和推理,难以在工业应用中部署。总结以往的研究经验,针对遥感图像检测面临的这些关键性的挑战,本研究提出基于 YOLOv8n 模型的遥感图像检测框架 YOLOv8-EP,旨在综合考虑数据特性和检测模型的适配性,通过多模块设计实现低误检率、低漏检率以及高效的检测性能^[21]。本文的主要贡献为:

1) 考虑到融合遥感图像中更多有用的特征信息,在 Neck 部分构建特征聚焦扩散金字塔网络(feature focus diffusion pyramid network, FFDPN),更好的捕获遥感图像目标的不同尺度和上下文信息,学习更强大的特征并降低漏检率。

2) 引入简单且无参数注意力模块(simple attention module, SimAM),更加关注特征图全局的细粒度特征,增强网络感受野,以提高检测小目标和密集目标的精确性^[22]。

3) 提出一种适用性强的轻量化任务动态调整检测头(task align dynamic detection head, TADD),通过特征提取器从多个卷积层中学习任务交互特征,建立任务分支和定位的交互,以提升遥感目标的定位和分类性能并降低误检率。

4) 引入基于辅助边框的 IoU 损失 Inner-CIoU 损失函数,通过辅助边框计算 IoU 损失^[23],加速模型收敛。

1 优化的 YOLOv8-EP 算法

遥感图像的目标和复杂的背景呈现不平衡的比例,由于目标物的尺寸和形状具有差异性,在检测过程难以提取有效特征导致漏检。误检则是目标物和背景之间具有极强的相似性导致的,然而在实践过程中除了这一因素外,检测网络学习能力不足以及难以高效融合多尺度特征也会造成误检。为解决这些潜在问题,如图 1 所示,本研究设计了特征聚焦扩散金字塔网络 FFDPN 替换原始的 PANet 结构,在提取丰富特征图细节的同时有效融合更多的局部和全局特征信息。在颈部改进 FPN 的基础上,将检测头替换为轻量化^[24] 的 TADD 检测头大幅度提升目标的分类和定位性能,并大大降低了网络复杂度,实现更加高效的检测效果。此外,为了不增加网络计算成本,引入 SimAM 注意力机制,提高目标区域细节信息的关注度的同时提升小目标和密集目标的检测性能。这 3 个部分设计如图 1 所示,改进部分使用虚线标出。

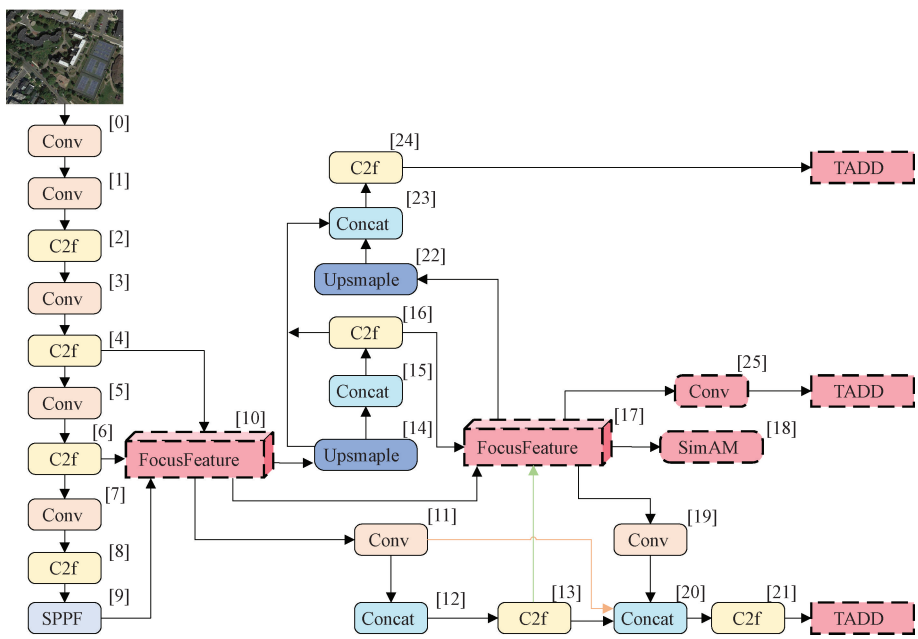


图 1 YOLOv8-EP 网络框架

Fig. 1 YOLOv8-EP network framework

1.1 改进的 FFDPN 结构

原始的 YOLOv8 网络^[25]的颈部采用路径聚合网络 (path aggregation network, PAN) 和特征金字塔网络 (feature pyramid networks, FPN) 增强特征融合能力。然而在实际应用中,这种结构在面临大量遥感图像检测时,会忽略主要的特征图信息,从而影响检测的准确性。为解决此类问题,本研究设计 FFDPN 框架,通过特征聚合和扩散的方法,实现多尺度特征的信息交互。首先,将 P_3 、 P_4 、 P_5 层捕捉的不同尺度的信息输入 FocusFeature 模块,聚焦并优化特征图中的重要信息, P_3 和 P_5 保留原始信息分别

与 FocusFeature 模块的输出特征通过上采样和 3×3 卷积后的特征图聚合多分辨率的特征,以提高模型检测不同大小目标的能力。其次,使用 C2f 模块融合不同尺度的特征,进一步优化拼接后的特征图,使信息更加集中和精炼。最后,将 C2f 模块、FocusFeature 模块和上采样处理后的特征信息输入下一个 FocusFeature 模块进行信息聚合,再通过扩散机制使具有丰富的上下文信息的特征扩散到各个检测尺度,提高特征表达的质量,FFDPN 结构能够有效降低原模型对遥感图像的关注度不足造成的漏检和误检问题。具体实现框架如图 2 所示。

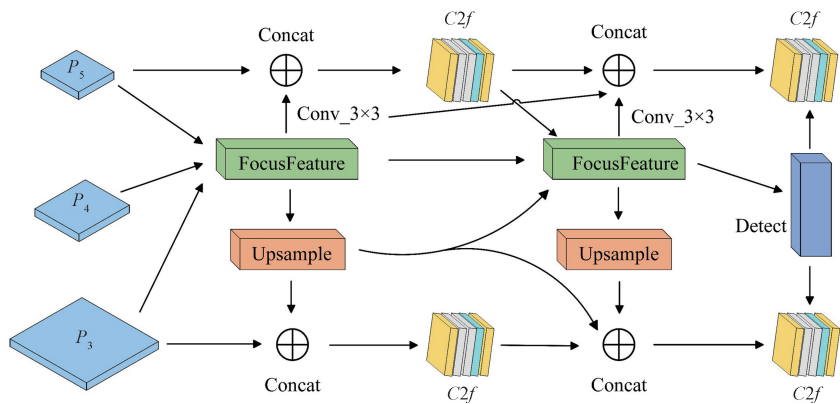


图 2 特征聚焦扩散金字塔网络结构图

Fig. 2 Structure of feature focus diffusion pyramid network

1.2 FocusFeature 模块

在特征融合阶段,以往融合方法无法充分实现各类遥感图像特征的多尺度信息交互。尤其在处理包含大量的

小目标和背景复杂的遥感图像时,会引入额外的计算负担,在高层特征融合时,导致特征冗余、参数增加。该模块的设计受到特征提取骨干网络 (poly kernel inception

network, PKINet)^[26]设计思想的启发,具体实现过程如图 3 所示。

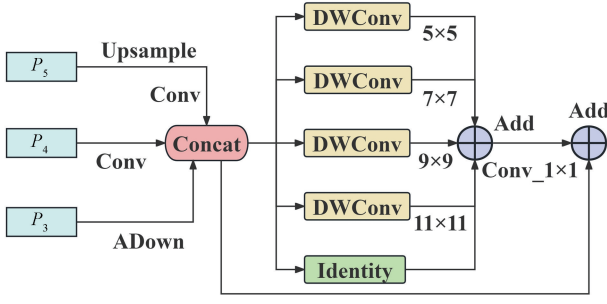


图 3 FocusFeature 模块

Fig. 3 FocusFeature module

FocusFeature 模块接收不同尺度的特征输入, P_5 经过上采样卷积增加其空间分辨率和 P_4 匹配, P_4 使用卷积调整通道, P_3 则经过下采样操作 (ADown) 减少特征图空间维度, 与 P_4 和 P_5 匹配。将调整完成的特征图沿着通道维度进行拼接, 融合更多有效信息。计算过程为:

$$F_{Concat} = \text{Concat} \begin{bmatrix} \text{ADown}(P_3), \text{Conv}(P_4), \\ \text{Conv}(\text{UpSample}(P_5)) \end{bmatrix} \quad (1)$$

通过平均池化减少特征图的空间维度, 同时经过分支路径提取不同的特征, 最后再通过 Concat 组合特征, 得到信息更加丰富的特征图。不同卷积核大小的深度可分离卷积 (depthwise separable convolution, DWConv) 用来捕捉不同尺度的特征^[27], 该卷积能够降低网络所需要的参数。每个 DWConv 生成一个独立的输出特征图, 同时通过恒等映射 Identity 提供一个跳跃连接, 保证信息的有效传递和模型训练的稳定性, 并保留原始特征不同尺度的卷积效果, 以此降低遥感目标的漏检率。图 4 展示了 ADown 下采样流程, 计算过程如式 (2) 和 (3) 所示。

$$F_{n \times n} = \text{DWConv}_{n \times n}(F_{Concat}), n = (5, 7, 9, 11) \quad (2)$$

$$F_{identity} = F_{Concat} \quad (3)$$




图 4 ADown 下采样

Fig. 4 ADown downsampling

最后, 将特征图通过 Add 拼接后得到组合特征图, 经过 1×1 卷积, 减少通道数至所需的输出维度。组合特征图与 Concat 操作后的融合特征通过 Add 拼接, 得到更加

全面和精细化的遥感图像各类目标特征, 最终的特征融合结果记为 F_{out} 。

$$F_{Add} = F_{5 \times 5} + F_{7 \times 7} + F_{9 \times 9} + F_{11 \times 11} \quad (4)$$

$$F_m = F_{Add} + F_{identity} \quad (5)$$

$$F_{out} = \text{Conv}_{1 \times 1}(F_m) \quad (6)$$

1.3 SimAM 注意力机制

现有的注意力机制通常沿着通道或空间维度细化特征, 局部特征之间的相互关联未被充分建模, 从而影响整体遥感图像的检测性能。为此, 本研究在 YOLOv8n 网络中引入 SimAM 注意力机制, 增强对遥感图像中飞机、舰船等小目标和密集目标的关注度进而提高检测性能^[28], 如图 5 所示。




图 5 SimAM 注意力机制

Fig. 5 SimAM attention mechanism

SimAM 注意力机制通过判别某个特征点的特征, 根据特征向量产生权重, 使得模型能够更关注于具有辨别力的特征, 在捕捉图像中关键信息的同时, 抑制不相关背景的干扰。SimAM 注意力机制通过能量函数计算每个特征向量的权重, 最小能量函数的计算如式 (7) ~ (9) 所示。

$$E = \frac{4(\sigma^2 + \lambda)}{(t - \mu)^2 + 2\sigma^2 + 2\lambda} \quad (7)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (\chi_i - \mu)^2 \quad (8)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N \chi_i \quad (9)$$

式中: E 表示能量函数, 衡量特征在激活过程中应当分配的权重, N 为能量函数的个数, σ^2 和 μ 分别代表方差和均值, t 是每个特征的原始输入值, λ 是用于控制噪声水平的参数, χ_i 表示第 i 个输入特征。当 E 数值越大, 目标物的特征越容易被忽略。使用 sigmoid 函数对计算的能量 E 进行非线性映射, 并与输入特征相乘, 得到重构后的特征。

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (10)$$

该注意力机制不需要通过额外的卷积操作与复杂的计算注意力分布, 能够有效避免训练难度高和增加计算负担的风险。

1.4 任务动态调整检测头 TADD

YOLOv8n 的检测头基于固定网格单元进行边界框预测,这种设计在局部细节捕捉方面存在精度限制。此外,遥感图像中的小物体特征在网络深层容易丢失,在边界框高度重叠的情况下,特征图分辨率较低,导致边界框预测不准确。为解决小目标漏检的问题,本文设计了轻量化的 TADD 检测头,在能够捕捉更多细节信息精准预测的同时降低网络计算成本。该检测头通过两个共享的 3×3 卷积在保持相似感受野的情况下减少了计算复杂度,同时引入分组归一化 (grouping normalization, GN),以稳定训练并加速模型收敛。通过 Concat 操作将不同尺度的特征图进行连接,生成交互特征,增强模型对不同尺寸目标的检测能力。

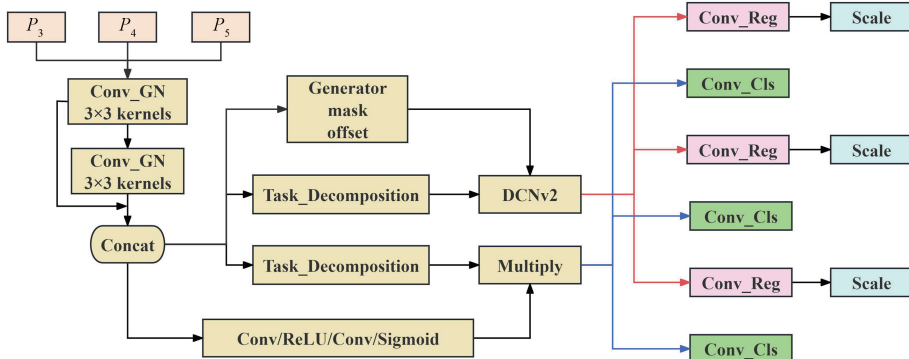


图 6 任务动态调整检测头原理图

Fig. 6 Schematic diagram of task align dynamic detection head

1.5 损失函数

YOLOv8 采用 CIOU 损失函数进行边界框回归, CIOU 损失函数的计算过程如式(11)所示。

$$L_{CIOU} = 1 - IOU(A, B) + \frac{\rho^2(P, P^{gt})}{c^2} + \alpha v \quad (11)$$

式中: $IOU(A, B)$ 表示真实框和预测框面积的交集与二者并集之比; ρ 计算的是 P 与 P^{gt} 之间的欧式距离; P 是预测框中心点; P^{gt} 是真实框中心点; c 表示同时包含两个框最小外接矩形的对角线长度; α 是权重系数; v 是度量纵横比的相似性指数。但是,在遥感图像中应用 CIOU 损失函数存在尺度适应性不足的问题,难以平衡多尺度目标之间的定位精度,从而无法获得最佳检测效果。本研究引入 Inner-CIOU 损失函数,该损失函数通过辅助边框计算 IOU 损失,辅助边框的尺寸由尺度因子 $ratio$ 控制调节,根据数据集不断调整辅助边框的尺寸,在计算损失和加速模型收敛的同时提升遥感图像检测的泛化能力。Inner-IOU^[29] 损失函数如图 7 所示,具体的计算过程如式(12)~(18)所示。

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (12)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (13)$$

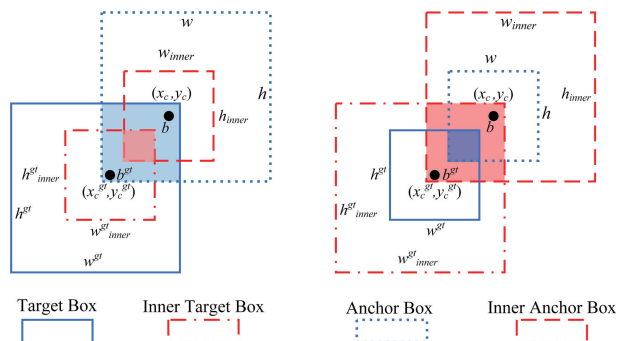


图 7 Inner-IOU 损失函数

Fig. 7 Inner-IOU loss function

$$b_l = x_c - \frac{w \times ratio}{2}, b_r = x_c + \frac{w \times ratio}{2} \quad (14)$$

$$b_t = y_c - \frac{h \times ratio}{2}, b_b = y_c + \frac{h \times ratio}{2} \quad (15)$$

$$inter = (\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \times (\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)) \quad (16)$$

$$union = (w^{gt} \times h^{gt}) \times ratio^2 + (w \times h) \times ratio^2 - inter \quad (17)$$

$$IoU^{inner} = \frac{inter}{union} \quad (18)$$

其中, (x_c^{gt}, y_c^{gt}) 表示真实框内部中心点位置; (x_c, y_c) 表示预测框内部中心点位置; $inter$ 和 $union$ 表示真实

框与预测框的交集和并集部分。图 7 中标明了各个框的边界长度,尺度因子 $ratio$ 控制调节各个辅助框的大小。如式(19)所示,将 Inner-IoU 应用至基于 CIoU 的边框回归损失函数中,得到 $L_{Inner-CIoU}$, 以此提高遥感图像检测的鲁棒性和灵活性。

$$L_{Inner-CIoU} = L_{CIoU} + IoU - IoU^{inner} \tag{19}$$

2 实验与结果分析

2.1 数据集

为了更加客观地分析改进算法在遥感图像检测方面的卓越性,本实验采用西北工业大学于 2014 年发布的 NWPU VHR-10 遥感图像数据集^[30]和武汉大学于 2015 年发布的 RSOD 数据集^[31]。其中,NWPU VHR-10 数据集包含 650 张有目标图像和 150 张无目标的背景图像,共包含 10 个类别的 3 775 个对象实例,空间分辨率为 0.08~2 m,并采用水平边界框(horizontal bounding box,HBB)进行标注,本实验中采用有目标的 650 张图像数据。RSOD 数据集包含 976 幅遥感影像和 6 950 个目标实例,共有飞机、油箱、运动场和立交桥 4 种不同的类别^[32]。实验中按照 8:1:1 比例划分训练集、验证集、测试集,划分结果如图 8 所示。




图 8 各数据集划分结果

Fig. 8 Results of the division of each dataset

2.2 实验环境与参数设置

为了提高训练效率,所有原始图像经过像素转换后尺寸统一调整为 640×640 ,以减少计算资源的消耗。此外,采用 Mosaic 数据增强技术以增强模型的泛化能力。在全部实验中,训练周期(Epoch)设定为 300,批量大小(Batch Size)设置为 32,使用 Adam 优化器对学习率进行优化调整。最大学习率设定为 1×10^{-2} ,最小学习率设置为 1×10^{-4} ,学习率调整策略采用余弦退火算法。具体实验环境如表 1 所示。

为了更加直观地展示 Mosaic 数据增强技术的优势,在原始 YOLOv8n 网络中选取照亮式生成对抗网络(enlighten generative adversarial network, EnlightenGAN)、交互式对比度增强算法(Icenet for Interactive co- ntrast enhancement, IceNet)、低照度增强网络(robust retinex decomposition network, RRDNet)、自

表 1 实验环境与参数设置

Table 1 Experimental environment and parameter settings

| 名称 | 版本 |
|---------|---------------------------------------|
| 操作系统 | Windows11 |
| 内存 | 64 GB |
| GPU | NVIDIA GeForce RTX 4060 |
| CPU | Intel(R) Core(TM) i9-13900HX 2.20 GHz |
| Python | Python(3.8.19) |
| PyTorch | PyTorch(2.2.2) |
| CUDA | CUDA (12.1) |

校准照明网络(self-calibrating illumination network, SCI)等 4 种常用的数据增强方法与 Mosaic 数据增强技术进行对比,讨论在 RSOD 数据集上使用不同数据增强方法对于网络的适配性。不同增强方法的对比效果如表 2 所示。

表 2 不同图像增强方法对比

Table 2 Comparison of different image enhancement methods

| 增强方法 | MAP50/% |
|--------------|---------|
| — | 93.8 |
| EnlightenGAN | 94.6 |
| IceNet | 94.8 |
| RRDNet | 95.2 |
| SCI | 95.6 |
| Mosaic | 96.4 |

表 2 中与其他数据增强方法的对比能够看出,本研究使用 Mosaic 数据增强方法对于遥感图像检测的检测精度都是最高,证明了该方法能够更有效处理遥感图像。为之后模块调整创造条件,可以更好的适配网络模型。

2.3 评价指标

为了全面评估模型的检测性能,本实验采用精确率(Precision, P)、召回率(Recall, R)、F1 评分(F1 score, F1)、参数量(Parameter)、浮点运算量(giga floating point operations, GFLOPs)以及平均精度均值(mean average precision, mAP)作为评估指标^[33]。具体计算方法如式(20)~(24)所示。

$$P = \frac{TP}{(TP + FP)} \tag{20}$$

$$R = \frac{TP}{(TP + FN)} \tag{21}$$

$$AP = \int_0^1 P(R) dR \tag{22}$$

$$mAP = \frac{1}{N} \sum_{m=1}^N AP_m \tag{23}$$

$$F1 = \frac{2TP}{2TP + FP + FN} \tag{24}$$

2.4 与基线模型的对比实验

为了客观评估 YOLOv8-EP 网络在遥感图像目标检测中的性能,本研究将原始 YOLOv8 模型及其改进版本在 NWPU VHR-10 数据集和 RSOD 数据集进行训练。训练过程中,采用了 300 轮迭代,且在每一轮中根据不同模块的协同优化策略逐步调整模型的参数设置。具体来说, YOLOv8-EP 网络中引入的不同模块,经过统一调参后,得到了最优的训练效果。表 3 和表 4 分别列出原始 YOLOv8 模型及其改进版本经过 300 轮迭代训练后,不同类别的遥感图像目标检测任务对应的评估指标。从表 3 可以看出,基线网络在 airplane 类和 ground track field 类达到了比改进网络更高的检测效果,平均精度比 YOLOv8-EP 高出 0.2%,表明基线网络对识别局部目标特征具有一定的实用性。但是,整体的精确率与召回率不如 YOLOv8-EP 算法,尤其 ship 和 tennis court 类的精确率较低,分别比改进网络低 6.0%和 5.5%,这是由于基线网络对小目标和背景的特征信息关注不足,以及难以高效融合局部特征的缺陷导致的。反观同一网络下的召回率,在 vehicle 类中基线网络仅达到了 80.7%,而改进算法达到了 87.6%,具有更低的漏检率。尤其是 basketball court 和 tennis court 类的 p 平均精度分别高出基线 6.9%和 8.5%,体现出 YOLOv8-EP 网络具有更好的鲁棒性。

表 4 的实验结果表明,改进网络在捕获更多的细节的同时能够达到更高的检测结果,尤其是 overpass 类的平均精度高出基线网络 3.9%,各类别的精确率和召回率普遍高于基线网络,验证了改进网络在检测各类遥感目标时优异的检测性能。

2.5 消融实验

为了进一步评估模块组成对 YOLOv8-EP 网络的贡献度和有效性,并对比各改进模块对模型性能的影响,在 NWPU VHR-10 数据集和 RSOD 数据集进行了消融实

表 3 NWPU VHR-10 数据集对比结果
Table 3 NWPU VHR-10 dataset comparison results

| 类别 | YOLOv8 | | | YOLOv8-EP | | |
|--------------------|--------|------|------|-----------|------|------|
| | P | R | AP | P | R | AP |
| airplane | 97.6 | 98.3 | 98.5 | 95.3 | 97.2 | 98.3 |
| ship | 92.3 | 97.6 | 98.2 | 98.3 | 98.0 | 98.5 |
| storage tank | 93.9 | 94.6 | 97.8 | 96.5 | 98.9 | 98.7 |
| baseball diamond | 93.7 | 95.2 | 98.0 | 97.9 | 98.6 | 98.3 |
| tennis court | 92.3 | 87.3 | 89.6 | 97.8 | 94.3 | 98.1 |
| basketball court | 90.6 | 86.2 | 91.0 | 95.8 | 93.4 | 97.9 |
| ground track field | 93.8 | 95.4 | 96.9 | 97.3 | 94.5 | 96.7 |
| harbor | 93.6 | 92.1 | 96.5 | 96.8 | 97.9 | 98.4 |
| bridge | 94.4 | 96.2 | 97.6 | 97.5 | 98.4 | 98.8 |
| vehicle | 86.8 | 80.7 | 90.2 | 89.8 | 87.6 | 92.3 |
| Avg | 92.9 | 92.4 | 95.4 | 96.3 | 95.9 | 97.6 |

表 4 RSOD 数据集对比结果
Table 4 Comparison results of RSOD datasets

| 类别 | YOLOv8 | | | YOLOv8-EP | | |
|------------|--------|------|------|-----------|------|------|
| | P | R | AP | P | R | AP |
| aircraft | 97.1 | 91.3 | 98.2 | 98.5 | 91.4 | 98.4 |
| oiltank | 98.3 | 92.2 | 96.4 | 96.3 | 92.1 | 98.5 |
| overpass | 92.5 | 84.3 | 92.0 | 92.7 | 96.8 | 95.9 |
| playground | 94.0 | 95.6 | 98.8 | 94.5 | 98.6 | 98.7 |
| Avg | 95.5 | 90.9 | 96.4 | 95.5 | 94.7 | 97.9 |

验。表 5 和表 6 分别列出以 YOLOv8 模型为基线,在不同数据集中引入各模块的实验结果。其中“√”表示使用了相应模块,空白则表示未使用该模块。

表 5 NWPU VHR-10 数据集的消融实验结果
Table 5 Results of ablation experiments on the NWPU VHR-10 dataset

| 模块 | FFDPN | TADD | SimAM | Inner-CIoU | F1 | mAP50/% | Params/ 10^6 | GFLOPs |
|----------|-------|------|-------|------------|------|---------|----------------|--------|
| Baseline | | | | | 92.7 | 95.4 | 3.01 | 10.2 |
| a | √ | | | | 93.1 | 95.6 | 3.05 | 9.5 |
| b | | √ | | | 92.7 | 95.9 | 2.25 | 8.7 |
| c | | | √ | | 92.6 | 95.2 | 3.01 | 10.1 |
| d | √ | √ | | | 93.4 | 97.0 | 2.62 | 9.6 |
| e | √ | | √ | | 93.6 | 96.7 | 3.05 | 9.5 |
| f | | √ | √ | | 94.9 | 96.8 | 2.25 | 8.9 |
| g | √ | √ | √ | | 95.8 | 97.3 | 2.62 | 8.7 |
| h | √ | √ | √ | √ | 96.1 | 97.6 | 2.62 | 8.7 |

通过表 5 的消融实验结果可以看出,在引入 FFDPN 融合多尺度特征后,使用多层次特征图的连接和处理,模

型能够更加灵活地捕捉不同大小目标的特征,F1 得分和 mAP50 分别提高了 0.4%和 0.2%,证明其能够充分融合

更多的上下文信息。为了优化 FFDPN 模块的效果,设置了不同的尺度权重和特征图分辨率,以保证在各个尺度上提取到充分的特征信息。相比于 YOLOv8 基线,单独添加设计的 TADD 检测头后,通过特征共享和并行任务处理,mAP50 提高了 0.5%,参数量下降 0.76 M,GFLOPs 仅为 8.7,然而,单一地加入 SimAM 注意力机制后,反而使得网络权重分配不合理,导致特征图的表示能力下降,实验效果不理想。为了避免这一问题,采用了 SimAM 与 FFDPN 和 TADD 检测头的联合优化,在训练过程中进行了学习率和注意力分配策略的调节,使得注意力机制能够更好地与其他模块协同工作,提升了检测精度。在组合模型实验

中,最终取得了较好的检测性能。

表 6 的实验结果与表 5 类似,相比单一模块的引入与替换,在同时引入 FFDPN 和 TADD 检测头后,模型的 F1 得分和 mAP50 分别提高了 1.2%和 0.7%,提升幅度并不高。通过对比分析,发现其原因是同时使用这两个模块后,通道数发生变化,某些全局特征被忽略。为了解决这一问题,实验中对学习率进行逐步调节,并结合 Adam 优化器在训练过程中不断迭代调整学习率,以期搜索最优的学习率组合,进一步提高了检测精度,但模型的提升幅度仅为 0.7%。

表 6 RSOD 数据集的消融实验结果

Table 6 Results of ablation experiments on the RSOD dataset

| 模块 | FFDPN | TADD | SimAM | Inner-CIoU | F1 | mAP50/% | Params/ 10^6 | GFLOPs |
|----------|-------|------|-------|------------|------|---------|----------------|--------|
| Baseline | | | | | 93.1 | 96.4 | 3.01 | 10.2 |
| a | ✓ | | | | 93.2 | 96.6 | 3.05 | 9.5 |
| b | | ✓ | | | 93.5 | 96.8 | 2.25 | 8.7 |
| c | | | ✓ | | 92.9 | 96.2 | 3.01 | 10.1 |
| d | ✓ | ✓ | | | 94.3 | 97.1 | 2.62 | 9.6 |
| e | ✓ | | ✓ | | 93.6 | 96.7 | 3.05 | 9.5 |
| f | | ✓ | ✓ | | 94.7 | 97.3 | 2.25 | 8.9 |
| g | ✓ | ✓ | ✓ | | 94.9 | 97.8 | 2.62 | 8.7 |
| h | ✓ | ✓ | ✓ | ✓ | 95.1 | 97.9 | 2.62 | 8.7 |

在同时引入 FFDPN、TADD 检测头、SimAM 和 Inner-CIoU 损失函数后,检测精度达到了最优,F1 得分和 mAP50 分别提高了 2.0%和 1.5%,模型参数量下降 0.39 M,浮点运算量最终保持在 8.7。这一改进结果表明,4 种改进方法具有很高的契合性,各模块的组合引入不仅提高了模型的整体检测性能,还保持了较低的计算成本。在参数调优过程中,Inner-CIoU 损失函数的使用显著改善了边界框回归的精度,且通过调整损失函数的权重,使得模型在训练过程中能够更加关注关键目标区域,从而提高了最终的检测精度。

2.6 与其他模型的对比实验

为定性评价改进的 YOLOv8-EP 网络的检测效果,本研究选择了 Faster-RCNN、RetinaNet、SSD、YOLOv3、YOLOv5s、YOLOv5m、YOLOv7-tiny、YOLOv8n、YOLOv8s、RT-DETR、文献[34]、文献[35]、YOLOv9-c、YOLOv10s 与 YOLOv8-EP 模型。在相同的配置环境下,分别在 NWPU VHR-10 数据集和 RSOD 数据集进行对比实验,表 7 和表 8 列出各网络的检测对比结果。

从表 7 得到的实验结果可以看出,在 NWPU VHR-10 数据集中,YOLOv8-EP 网络的 mAP50 比 Faster-RCNN 和 SSD 算法高出 20.0%和 18.9%。同时,相较于其他 YOLO 模型具有明显的优势,其 mAP50 值分别比

表 7 NWPU VHR-10 数据集的对比实验结果

Table 7 Comparative experimental results for the NWPU VHR-10 dataset

| 算法 | Backbone | F1/ % | mAP50/ % | Params/ 10^6 |
|-------------|---------------|----------|-------------|-------------------|
| Faster-RCNN | ResNet50 | 76.8 | 77.6 | 114.34 |
| RetinaNet | ResNet50 | 75.9 | 78.2 | 55.4 |
| SSD | VGG16 | 75.7 | 78.7 | 104.6 |
| YOLOv3 | Darknet53 | 78.9 | 82.5 | 103.70 |
| YOLOv5s | CSP-Darknet53 | 84.6 | 88.5 | 7.10 |
| YOLOv5m | CSP-Darknet53 | 87.5 | 91.5 | 29.25 |
| YOLOv7-tiny | Darknet53 | 87.4 | 91.9 | 6.06 |
| YOLOv8n | Darknet53 | 92.7 | 95.4 | 3.01 |
| YOLOv8s | Darknet53 | 89.3 | 92.7 | 11.14 |
| RT-DETR | HGNetv2 | 92.3 | 94.3 | 32.85 |
| 文献[34] | Darknet53 | 92.6 | 94.6 | — |
| 文献[35] | ResNet50 | — | 94.8 | 49.9 |
| YOLOv9-c | — | 89.0 | 92.4 | 25.34 |
| YOLOv10s | — | 86.4 | 93.0 | 8.06 |
| YOLOv8-EP | Darknet53 | 96.1 | 97.6 | 2.62 |

表 8 RSOD 数据集的对比实验结果

Table 8 Comparative experimental results for the RSOD dataset

%

| 算法 | F1 | mAP50 | AP | | | |
|-------------|------|-------|----------|---------|----------|------------|
| | | | aircraft | oiltank | overpass | playground |
| Faster-RCNN | 79.6 | 81.5 | 87.9 | 92.3 | 72.5 | 73.3 |
| RetinaNet | 82.3 | 84.2 | 88.3 | 89.6 | 78.4 | 80.5 |
| YOLOv3 | 86.8 | 89.3 | 90.7 | 97.7 | 79.6 | 89.2 |
| YOLOv5m | 92.3 | 93.4 | 92.7 | 97.2 | 86.1 | 97.4 |
| YOLOv5s | 94.5 | 95.1 | 94.4 | 98.1 | 89.4 | 98.5 |
| YOLOv7-tiny | 92.0 | 93.7 | 93.8 | 97.9 | 85.7 | 97.2 |
| YOLOv8s | 92.8 | 94.8 | 94.7 | 98.1 | 87.9 | 98.4 |
| YOLOv8n | 93.1 | 96.4 | 98.2 | 96.4 | 92.0 | 98.8 |
| YOLOv9-c | 90.0 | 94.2 | 95.7 | 96.0 | 91.1 | 94.1 |
| YOLOv10s | 92.3 | 94.9 | 97.4 | 96.3 | 89.4 | 96.5 |
| YOLOv8-EP | 95.1 | 97.9 | 98.4 | 98.5 | 95.9 | 98.7 |

YOLOv3、YOLOv5s、YOLOv5m、YOLOv6、YOLOv7-tiny、YOLOv8n 和 YOLOv8s 网络提高了 15.1%、9.1%、6.1%、11.3%、5.7%、2.2%和 4.9%，并且 F1 得分普遍高于其他网络模型。本文所提算法参数量仅为 2.62 M，能够满足低算力边缘设备的部署需求^[36]。

此外，表 8 的实验结果表明，本研究提出的改进模型的 F1 得分和 mAP 值普遍高于其他算法网络，在各个目标的检测中整体检测精度更加均衡，无类间跳跃性变化，具有更高的适用性。

图 9 直观的展示了 YOLO 系列各模型在训练过程中的




图 9 RSOD 数据集不同模型平均检测精度变化曲线

Fig. 9 Variation curves of mean average precision for different models in RSOD dataset

mAP 变化曲线。可以清晰地看到改进算法具有更高的 mAP 值,曲线整体相比其他算法模型更加稳定。在更换损失函数之后,相比 YOLOv8s、YOLOv9-c、YOLOv10s,在 300 个 Epochs 之后已经趋于收敛,说明 Inner-CIoU 能够有效加速模型收敛。相比以往算法在检测遥感图像目标时能够更加节省时间成本,可以为工业部署创造高效的条件。

3 可视化分析

为了更全面的分析 YOLOv8-EP 算法网络在不同遥感图像的检测性能,本研究选取 YOLOv8n 模型与改进的 YOLOv8-EP 算法进行对比,如图 10 和图 11 所示。其中,图 10(a)是 NWPU VHR-10 测试数据未检测的原图,在含有复杂背景的遥感目标检测任务中,YOLOv8n 容易出现

漏检和错检的情况,如图 10(b)的第 1 行产生漏检是由于 YOLOv8n 对遥感图像内部特征细粒度的关注不足,使得局部特征的提取能力下降,导致难以融合更多有效特征产生的。由于拍摄的多尺度以及背景与目标具有高度相似性,目标的纹理信息弱化,局部信息模糊,进而产生如图 10(b)第 2 行的误检现象。相比之下,YOLOv8-EP 检测模型利用 FFDPN 多尺度捕捉并融合更全面的上下文信息,可以有效排除干扰信息成功检测出舰船目标。同时利用 TADD 检测头和 SimAM 注意力对目标信息高效分类和定位,增强模型的感受野,从而降低误检率和虚警率,排除背景干扰。如图 10(c)所示,改进算法能够成功检测出飞机等有效目标。相比基线算法,改进的 YOLOv8-EP 算法网络能够有效避免漏检和误检问题的发生。

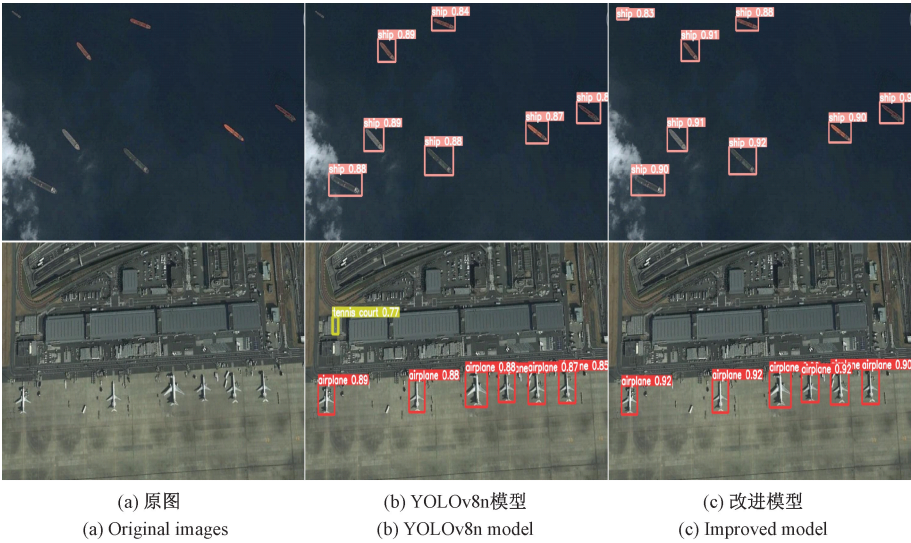


图 10 NWPU VHR-10 数据集检测结果
Fig. 10 NWPU VHR-10 dataset detection results

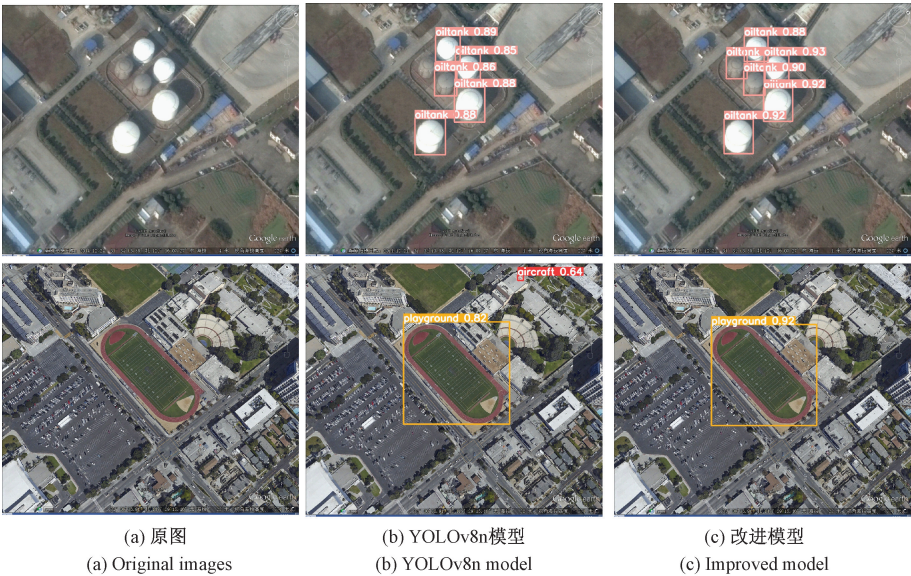


图 11 RSOD 数据集检测结果
Fig. 11 RSOD dataset detection results

类似的,图 11(a)是 RSOD 测试数据集的原图。图 11(b)分别漏检一个储罐,并在操场目标中误检出飞机场。然而,图 11(c)的改进模型却能够有效避免漏检和误检现象,这表明我们的方法在提高检测精度方面具有可靠性。综上所述,本研究算法与其他算法相比检测置信度更高,相较于原模型的测试结果各方面均有较大提升,在两个数据集的测试实验中均未发生漏检和误检,拥有更加高效和实用的检测性能。

图 12 和图 13 展示了在不同数据集中使用热力图可视化技术^[37],观察记录了部分图像在 YOLOv8n、YOLOv8n 加入 SimAM 注意力机制以及 YOLOv8-EP 算法网络中的执行过程。图 12(a)展示的是 NWPU VHR-10 数据集的原图,图 12(b)使用 YOLO v8n 网络,由于对飞机目标与港口目标的关注度不足,所以颜色分布区域少且梯度变化对比不明显。图 12(c)在加入 SimAM 注意力机制后,区域颜色对比增强,目标物体上的感兴趣区域更大,表明其能够增强目标物体的关注度。图 13(a)表示的是 RSOD 数据集的原图,

图 13(b)是原网络的热力图分布,可以看出 YOLOv8n 网络对机场和立交桥目标的关注度不足,颜色分布区域少且梯度变化对比不明显。图 13(c)在加入 SimAM 注意力机制后,颜色范围变广,表明其增加了网络感受野。图 12(d)和图 13(d)展示了 YOLOv8-EP 算法网络热力图可视化效果,相比于 YOLOv8n 和加入 SimAM 之后的 YOLOv8n 热力分布对比更为明显,特别是在飞机目标和立交桥目标的热力图上,感兴趣区域的范围显著增大。这得益于 YOLOv8-EP 网络中多个模块的协同优化,特别是在 FFDPN 和 TADD 检测头的作用下,网络能够更好地融合多尺度特征,提高对不同尺寸目标的检测能力。FFDPN 通过多层次特征图的融合,增强了网络对不同尺度目标的感知能力,而 TADD 检测头通过并行任务处理和特征共享,优化了检测头的表现,从而使得网络能够在不同目标尺度下都保持较好的关注度。与基线算法相比,YOLOv8-EP 网络通过这些模块的协同作用,不仅提升了检测精度,还有效扩大了感兴趣区域的范围,展现出更强的目标检测能力。

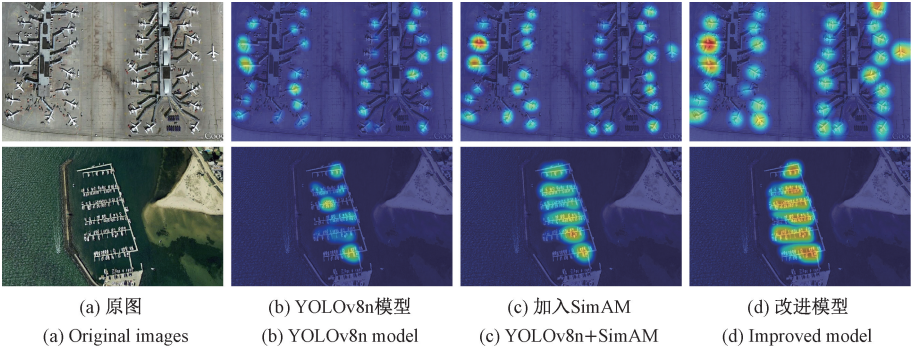


图 12 NWPU VHR-10 数据集热力图可视化
Fig. 12 Heat map visualisation of the NWPU VHR-10 dataset

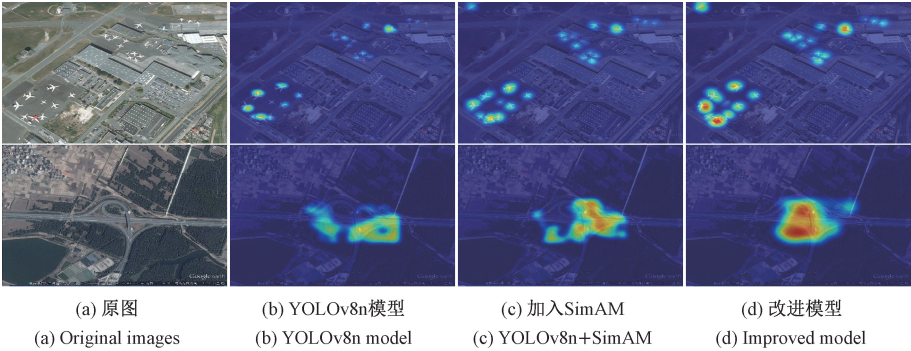


图 13 RSOD 数据集热力图可视化
Fig. 13 Heat map visualisation of the RSOD dataset

4 结 论

针对遥感图像背景复杂和目标尺度多变等问题,本研究提出一种改进的轻量化遥感图像目标检测算法 YOLO-

EP,有效避免了检测过程中易发生的漏检、错检现象,在降低模型参数数量的同时确保能够部署在边缘设备上。通过构建 FFDPN 模块,提高多尺度特征融合效果;引入 SimAM 注意力机制,在不增加网络负担的情况下增强对

小目标物体的关注度;设计了轻量化的 TADD 检测头,通过共享卷积大幅减少参数量,提高模型的分类和定位能力;使用 Inner-CIoU 损失函数,改善低质量图像对网络梯度的不利影响。在 NWPU VHR-10 数据集和 RSOD 数据集的实验结果表明,YOLOv8-EP 算法网络的设计策略优于以往的算法网络,相比基线网络 mAP 值分别提升了 2.2% 和 1.5%,参数量降低为基线模型的 87%,达到了期望的检测结果。未来可以考虑模型部署与应用等方面的工作,进一步验证网络在工业领域中的适用性与现实性。

参考文献

- [1] ZHAO H, CHU K B, ZHANG J, et al. Small-size target detection in remotely sensed image using improved multiscale features and attention mechanism[J]. IEEE Access, 2023, 11:56703-56711.
- [2] GUAN ZH H, MIAO X Y, MU Y J, et al. Forest fire segmentation from aerial imagery data using an improved instance segmentation model[J]. Remote Sensing, 2022, 14(13): 3159.
- [3] LI L, LU N, JIANG H, et al. Impact of deep convolutional neural network structure on photovoltaic array extraction from high spatial resolution remote sensing images[J]. Remote Sensing, 2023, 15(18):4554.
- [4] ADEGUN A A, FONOU D J V, VIRIRI S, et al. State-of-the-art deep learning methods for objects detection in remote sensing satellite images[J]. Sensors, 2023, 23(13): 5849.
- [5] WU J H, XU W, HE J F, et al. YOLO for penguin detection and counting based on remote sensing images[J]. Remote Sensing, 2023, 15(10):2598.
- [6] BAO Y G, GAO X J, WU Y CH, et al. Research progress of armor protection materials[C]. Journal of Physics: Conference Series, IOP Publishing, 2021, 1855(1): 012035.
- [7] PHAM M T, LUC C, FRIG-UET C O, et al. YOLO-fine: One-stage detector of small objects under various backgrounds in remote sensing images [J]. Remote Sensing, 2020, 12(15):2501.
- [8] LI P, CHE CH. SeMo-YOLO: A multiscale object detection network in satellite remote sensing images[C]. 2021 International Joint Conference on Neural Networks(IJCNN). IEEE, 2021: 1-8.
- [9] ZHANG ZH Y, LIU Y P, LIU T C, et al. DAGN: A real-time UAV remote sensing image vehicle detection framework[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 17(11): 1884-1888.
- [10] LI ZH, YUAN J H, LI G X, et al. RSf-YOLO: Object detection method for remote sensing images based on improved YOLO [J]. Sensors, 2023, 23(14): 6414.
- [11] ZHANG J R, CHEN ZH H, YANG X, et al. Faster and lightweight: An improved YOLOV5 object detector for remote sensing images [J]. Remote Sensing, 2023, 15(20): 4974.
- [12] TIAN B, CHEN H. Remote sensing image target detection method based on refined feature extraction[J]. Applied Sciences, 2023, 13(15):8694.
- [13] LIAO H, ZHU W Q. YOLO-DRS: A bioinspired object detection algorithm for remote sensing images incorporating a multi-scale efficient lightweight attention mechanism[J]. Biomimetics, 2023, 8(6): 458.
- [14] MA M Y, PANG H N. SP-YOLOv8s: An improved yolov8s model for remote sensing image tiny object detection[J]. Applied Sciences, 2023, 13(14):8161.
- [15] NIE H J, PANG H L, MA M Y, et al. A lightweight remote sensing small target image detection algorithm based on improved YOLOv8[J]. Sensors, 2024, 24(9): 2952.
- [16] WANG H Y, YANG H T, CHEN H, et al. A remote sensing image target detection algorithm based on improved yolov8 [J]. Applied Sciences, 2024, 14(4):1557.
- [17] LI Y L, DING M T, ZHANG Q, et al. Old landslide detection using optical remote sensing images based on improved YOLOv8 [J]. Applied Sciences, 2024, 14(3):1100.
- [18] 王子龙, 荣杰. 基于 YOLOv7-tiny 改进的遥感小目标检测算法[J]. 国外电子测量技术, 2024, 43(7):65-74.
WANG Z L, RONG J. An improved remote sensing small object detection algorithm based on YOLOv7-tiny[J]. Foreign Electronic Measurement Techniques, 2024, 43(7): 65-74.
- [19] 曲海成, 王蒙, 柴蕊. 双向多尺度特征融合的高效遥感图像车辆检测[J], 2024, 60(12):346-356.
QU H CH, WANG M, CHAI R. Efficient vehicle detection in remote sensing images with bi-directional multi-scale feature fusion[J]. Computer Engineering and Applications, 2024, 60(12): 346-356.
- [20] 邝先验, 程福军, 吴翠琴, 等. 基于改进 YOLOv7-tiny 的高效轻量遥感图像目标检测方法[J]. 电子测量与仪器学报, 2024, 38(7):22-33.
KUANG X Y, CHENG F J, WU C Q, et al. Efficient and lightweight remote sensing image object detection method based on improved YOLOv7-tiny[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 22-33.
- [21] SHAFIQUE A, CAO G, KHAN Z, et al. Deep

- learning-based change detection in remote sensing images: A review[J]. Remote Sensing, 2022, 14(4): 871.
- [22] CHANDRA N, VAIDYA H. Automated detection of landslide events from multisource remote sensing imagery: Performance evaluation and analysis of YOLO algorithms [J]. Journal of Earth System Science, 2024, 133(3):1-17.
- [23] ZHOU L M, ZHAO H, LIU ZH H, et al. MHLDet: A multi-scale and high-precision lightweight object detector based on large receptive field and attention mechanism for remote sensing images[J]. Remote Sensing, 2023, 15(18): 4625.
- [24] 张绍文, 史卫亚, 张世强, 等. 基于加权感受野和跨层融合的遥感小目标检测[J]. 电子测量技术, 2023, 46(18):129-138.
- ZHANG SH W, SHI W Y, ZHANG SH Q, et al. Remote sensing small target detection based on weighted receptive field and cross-layer fusion[J]. Electronic Measurement Technology, 2023, 46(18): 129-138.
- [25] QIAN X L, ZHANG N N, WANG W. Smooth GioU loss for oriented object detection in remote sensing images[J]. Remote Sensing, 2023, 15(5): 1259.
- [26] LI SH CH, HUANG H P, MENG X Y, et al. A glove-wearing detection algorithm based on improved YOLOv8[J]. Sensors, 2023, 23(24):9906.
- [27] ZHENG X, QIAN S R, WEI SH D, et al. The combination of transformer and you only look once for automatic concrete pavement crack detection [J]. Applied Sciences, 2023, 13(16): 9211.
- [28] LIU Q, HUANG W, DUAN X Q, et al. DSW-YOLOv8n: A new underwater target detection algorithm based on improved YOLOv8n [J]. Electronics, 2023, 12(18): 3892.
- [29] 曾富强, 张贞凯, 方梦瑶. 基于改进 ResNet18 的遥感图像舰船目标识别[J]. 电子测量技术, 2024, 47(12): 164-172.
- ZENG F Q, ZHANG ZH K, FANG M Y. Ship target recognition based on improved ResNet18 remote sensing image [J]. Electronic Measurement Technology, 2024, 47(12): 164-172.
- [30] HU Y L, LI Y, JIANG D M, et al. Remote sensing imagery object detection model compression via tucker decomposition[J]. Mathematics, 2023, 11(4):856.
- [31] TIAN Z W, HUANG J, YANG Y, et al. KCFS-YOLOv5: A high-precision detection method for object detection in aerial remote sensing images[J]. Applied Sciences, 2023, 13(1): 649.
- [32] 赵倩, 杨一聪. 多重金字塔的轻量化遥感车辆小目标检测算法[J]. 电子测量技术, 2023, 46(13):88-94.
- ZHAO Q, YANG Y C. Small target detection algorithm for lightweight remote sensing vehicle with multiple pyramids [J]. Electronic Measurement Technology, 2023, 46(13):88-94.
- [33] 田浩南, 张美君, 卜和阳. 基于多尺度分解的双曝光图像融合方法[J]. 国外电子测量技术, 2024, 43(9): 16-25.
- TIAN H N, ZHANG M J, BU H Y. Double exposure image fusion method based on multi-scale decomposition [J]. Foreign Electronic Measurement Technology, 2024, 43(9):16-25.
- [34] ZHAO D W, SHAO F M, LIU Q, et al. A small object detection method for drone-captured images based on improved YOLOv7 [J]. Remote Sensing, 2024, 16(6):1002.
- [35] DUAN J. Skip-encoder and skip-decoder for detection transformer in optical remote sensing [J]. Remote Sensing, 2024, 16(16):2884.
- [36] 周仿荣, 陈艳芳, 杨鹤猛, 等. 基于 GAN 网络的电力设施遥感图像去云算法研究[J]. 国外电子测量技术, 2024, 43(5):154-160.
- ZHOU F R, CHEN Y F, YANG H M, et al. Research on remote sensing image de-clouding algorithm for power facilities based on GAN network[J]. Foreign Electronic Measurement Technology, 2024, 43(5):154-160.
- [37] XU X, YU T, HU X, et al. SALMNet: A structure-aware lane marking detection network [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22(8): 4986-4997.

作者简介

李泽胤, 硕士研究生, 主要研究方向为图像处理和计算机视觉检测。

E-mail:15033510312@163.com

李栋(通信作者), 副教授, 主要研究方向为智能信息处理和计算机视觉技术。

E-mail:lidong@imut.edu.cn

房建东, 教授, 主要研究方向为信息处理与智能控制。

E-mail:lidong@imut.edu.cn

赵磊, 硕士研究生, 主要研究方向为图像处理与交通标志识别。

E-mail:zhaolei990323@163.com

张佳惠, 硕士研究生, 主要研究方向为图像处理与目标检测。

E-mail:m15101348341@163.com