

基于 YOLOv8L 遥感图像旋转目标检测

韩慧妍^{1,2,3}, 张秀权^{1,2,3}, 况立群^{1,2,3}, 韩 燮^{1,2,3}, 杨晓文^{1,2,3}

(1. 中北大学 计算机科学与技术学院, 山西 太原 030051; 2. 机器视觉与虚拟现实山西省重点实验室, 山西 太原 030051;

3. 山西省视觉信息处理及智能机器人工程研究中心, 山西 太原 030051)

摘要:针对遥感图像复杂背景下的目标(如船舶、飞机等)具有朝向任意、尺度变化较大、数量多、目标排列密集等特点,提出一种基于改进 YOLOv8L 的旋转目标检测算法,用带有角度的旋转框能够更加精确定位目标。首先,在网络 Head 部分增加解耦角度预测头,预测目标的角速度信息;其次,融合坐标注意力机制模块提高模型抑制噪声的能力;最后,在 Neck 部分引入自适应空间特征融合模块,抑制不同尺度特征图之间融合特征信息时的一致性,保留有效的信息并进行融合。实验结果表明,所提算法在 DOTA 数据集上的检测精度达到了 73.85%,较原有 YOLOv8L 模型提升了 3.53%。

关键词:旋转目标检测;注意力机制;解耦预测头;YOLO

中图分类号:TP75;P237 文献标识码:A DOI:10.3969/j.issn.1001-5078.2024.09.018

Rotating object detection of remote sensing image based on YOLOv8L

HAN Hui-yan^{1,2,3}, ZHANG Xiu-quan^{1,2,3}, KUANG Li-qun^{1,2,3}, HAN Xie^{1,2,3}, YANG Xiao-wen^{1,2,3}

(1. School of Computer Science and Technology, North University of China, Taiyuan 030051, China;

2. Shanxi Key Laboratory of Machine Vision and Virtual Reality, Taiyuan 030051, China;

3. Shanxi Province's Vision Information Processing and Intelligent Robot Engineering Research Center, Taiyuan 030051, China)

Abstract: The proposed algorithm utilizes an improved YOLOv8L model to detect rotating objects (such as ships and aircraft) in complex remote sensing images with arbitrary orientation, large scale variation, and dense array of objects. By incorporating a rotating frame with angle, the algorithm achieves more accurate target localization. Firstly, the decoupling angle prediction head is incorporated into the network's head section to accurately forecast the angular information of the target object. Secondly, by integrating a coordinate attention mechanism module, the model's capability to suppress noise is significantly enhanced. Lastly, an adaptive spatial feature fusion module is introduced in the neck section to effectively address inconsistencies in feature information fusion across different scales and retain valuable information for optimal fusion. The experimental results demonstrate that the proposed algorithm achieves a detection accuracy of 73.85% on the DOTA dataset, surpassing the original YOLOv8L model by 3.53%.

Keywords: rotating object detection; attention mechanism; decoupling angle prediction head; YOLO

基金项目:山西省自然科学基金项目(No. 202303021211153);山西省科技重大专项计划“揭榜挂帅”项目(No. 202201150401021);国家自然科学基金项目(No. 62272426)资助。

作者简介:韩慧妍(1980-),博士,副教授,研究方向为人工智能、虚拟现实。E-mail:hhy980344@163.com

收稿日期:2023-11-01

1 引言

目标检测是计算机视觉的基本任务之一,为下游任务提供目标的定位信息和类别信息。目前关于水平目标检测器^[1]的研究很多,对于旋转目标检测的研究相对较少。遥感图像^[2]具有目标小、密集排列、数量众多、背景复杂、目标朝向任意等特点,直接应用水平目标检测器检测遥感图像,无法计算目标的方向信息,同时勾勒出的检测框包含大量的非目标特征,一定程度上降低了目标定位的精确度,另外,当检测图像包含目标数量过多时,水平检测框相互遮盖,不利于精确定位目标。

受益于水平目标检测器的快速发展,越来越多的旋转目标检测器逐渐出现,并且借鉴了水平目标检测器的优点。在旋转目标检测器中,使用与水平目标检测类似的坐标回归方法,直接预测角度回归参数,但基于回归的角度预测往往会引入边界不连续问题^[3-4],由于预测结果超出了规定的角度范围,边界处的损失急剧增加。因此,模型在预测目标边界处的角度时更加困难,增加了模型的预测成本。为了解决边界不连续问题,大部分研究通过对损失函数增加约束或改变计算方式来消除损失的突然增加,如 IOU Smooth L1 Loss^[3]和 Modulated Loss^[4],其优点是可以从水平目标检测器中借鉴成熟的基线,并重用相关技术提高检测性能。然而,这些方法无法消除边界不连续行为。最近 Yang 等人提出圆形光滑标签 (Circular Smooth Label, CSL)^[5]对角度预测进行离散化编码,解决边界不连续问题。Yang 等人^[6]将旋转边界框模型化为高斯分布,并提出高效的 IOU-Based Loss,避免直接对角度进行回归。

当前目标检测算法生成候选框的方式主要分为 anchor-based 和 anchor-free。anchor-based 目标检测算法在很多领域取得了不错的结果,但仍有难以避免的缺点:网络对 anchor 的大小、长宽比值很敏感,当使用不同超参数时,网络的检测性能会发生很大的波动;anchor 一旦设定好后,在网络训练过程中就无法改变,限制了检测器的广泛应用。最近,anchor-free 检测算法不再使用 anchor,采用直接检测关键点的方式,减少网络中需要设置的超参数数量。

YOLOv8L 目标检测算法是 YOLO 系列算法的新版本,YOLOv8L 摒弃了 anchor-based 算法,直接预

测目标的中心点而不是已知锚框的偏移量。本文充分借鉴先进水平目标检测器和旋转目标检测器的优秀思想,以 YOLOv8L 模型的 Backbone 模块为基础网络架构,提出一种基于 anchor-free 的旋转目标检测算法 YOLOv8L-r,用于旋转目标检测:

(1)解耦的角度预测分支:在 YOLOv8L 的 Head 模块中,新增一个预测参数:检测框的角度 θ 。大多数的旋转目标检测器,将检测框的角度 θ 与检测框的位置参数 (x, y, w, h) 放到同一个回归分支中进行预测。借鉴 YOLOv8L 将检测头分成两个分支,本文使用了目前主流的解耦头结构 (Decoupled-Head),在网络 Head 模块中新增了一个独立预测分支用来提取目标的角度特征。

(2)针对遥感图像背景复杂的问题,在网络的 Backbone 和 Head 阶段引入坐标注意力机制 (Coordinate Attention, CA)^[7] 模块,提高网络在复杂背景中对目标特征的提取能力。

(3)考虑增强网络融合不同维度特征信息的能力,提高网络的分类和定位精度,在 Neck 阶段引入自适应空间特征融合 (Adaptively Spatial Feature Fusion, ASFF)^[8],抑制特征金字塔不同尺度特征的不一致性,保留有用的信息进行融合。

2 算法描述

2.1 YOLOv8L 网络原理

YOLOv8L 网络结构分为输入端 (Input)、主干网络 (Backbone)、颈部 (Neck)、预测头 (Head) 四部分。主干网络由 CBS, C2F, 更快的空间金字塔池化 (Spatial Pyramid Pooling-Fast, SPPF) 组成, CBS 包括卷积层 (Convolution)、正则化层 (Normalization)、激活函数 (Activation) 三部分,激活函数为 Silu; C2F 包含两个普通卷积操作和 BottleNeck 操作,每个 BottleNeck 的输出会被拼接到一起作为最终的输出; Neck 部分采用流行的路径聚合网络 (Path Aggregation Network, PAN) 结构, PAN 相比于特征金字塔 (Feature Pyramid Network, FPN) 在网络中添加了一条自下向上的特征融合路径,确保输出的每一个特征图既包含丰富的语义信息也包含丰富的细节信息。Head 部分使用解耦结构,通过两条独立但结构相同的分支分别预测目标的分类信息和定位信息。本文使用的 YOLOv8L 详细网络结构如图 1 所示, C2F 结构如图 2 所示。

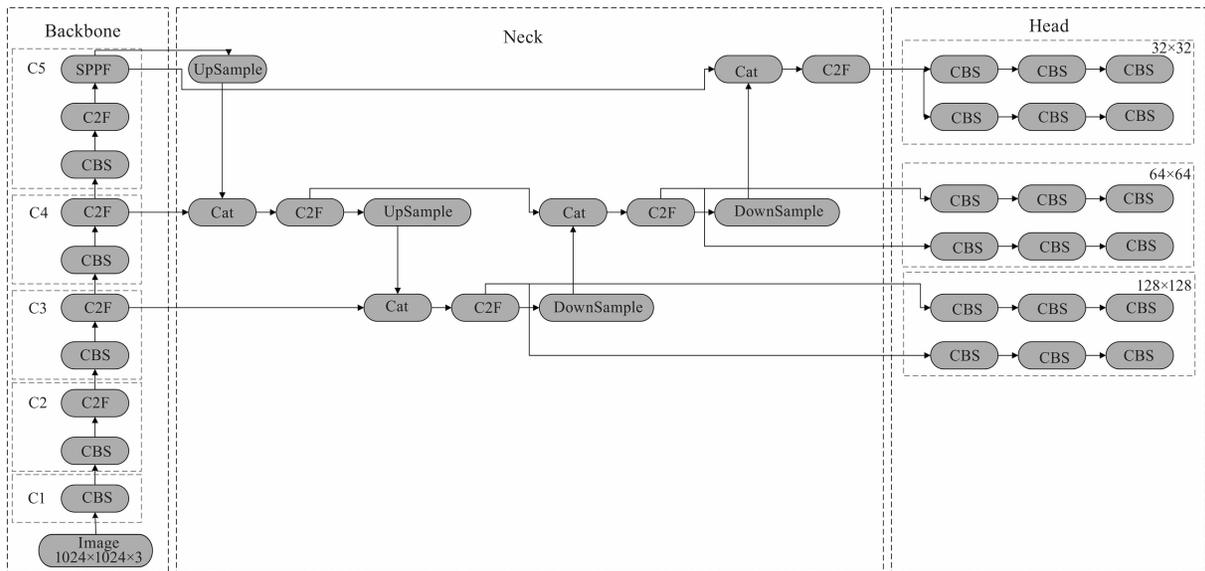


图 1 YOLOv8L 网络结构图

Fig. 1 Structure of YOLOv8L network

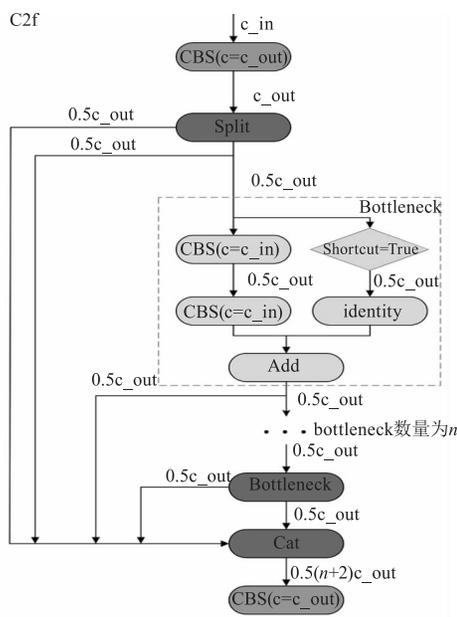


图 2 C2F 网络结构图

Fig. 2 Structure of C2F network

2.2 网络改进部分

虽然 YOLO 系列算法在通用目标检测领域有不错的效果,但直接将其应用在遥感图像领域时仍存在问题:遥感图像目标具有高的长宽比、任意朝向、密集排列等特点,水平预测算法无法获得目标本身的方向信息,准确度下降。针对此问题,本文以 YOLOv8L 算法为基准进行改进,提出了 YOLOv8L-r。YOLOv8L-r 网络模型的总体架构与 YOLOv8L 相似。改进之后的 YOLOv8L-r 的总体架构如图 3 所示, YOLOv8L-r 增加了网络对旋转边界框的检测性能。

在本节中,将详细介绍针对提升网络旋转检测性能所做的改进。

2.2.1 模型基准

在目标检测领域,正负样本不平衡问题一直是困扰目标检测算法的一大难题。因此,本文引入 FCOSR Assigner 和 ProbIoU Loss 作为基准。采用 FCOSR Assigner 作为网络的正负样本分配策略, ProbIoU Loss 作为网络损失函数。网络的 Backbone 和 Neck 部分与 YOLOv8L 保持一致,Head 部分的回归分支新增一个角度参数 θ ,回归分支预测参数由原来的 4 个参数 (x, y, w, h) 修改为 5 个参数 (x, y, w, h, θ) 作为旋转边界框的表示方式。

2.2.2 增加基于角度标签的旋转检测头分支

为了获得目标的方向特征,使得网络具备检测目标角度信息的功能,在 YOLOv8L 的检测阶段加入角度预测分支。

解耦角度检测头。借鉴 YOLOv8L 解耦检测头的设计思想,本文采用一个独立的分支单独提取角度特征。大多数旋转目标检测器将旋转边界框的角度参数与其定位参数放在同一个回归分支中进行预测。角度参数 θ 与定位参数 (x, y, w, h) 使用的是相同的特征,干扰了网络对角度参数的回归。所以,本文设计了一个独立的分支来单独提取角度特征,预测旋转边界框的角度信息。采用 ProbIoU Loss 作为回归损失函数,联合优化参数 (x, y, w, h, θ) 。

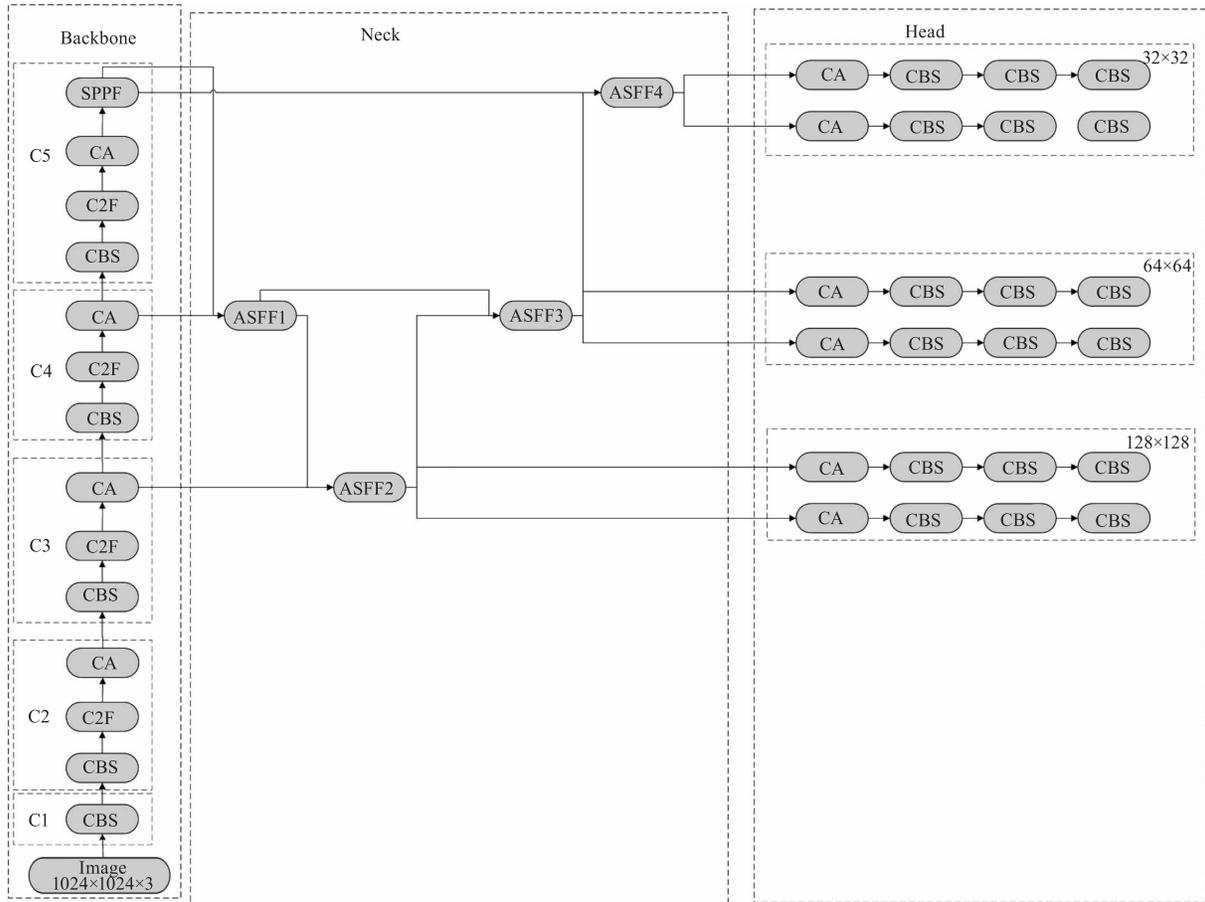


图3 YOLOv8L-r 网络结构图

Fig. 3 structure of YOLOv8L-r network

2.2.3 融合坐标注意力机制

注意力机制常用来选择特征图中需要关注的位置,提升模型特征提取的性能。本文引入了坐标注意力机制 CA,提高模型的特征提取能力。相比于其他注意力机制,CA 同时关注特征图的位置信息与空间信息,重点关注特征图的宽和高两个方向上的信息,使得网络注意力可以关注特征图更大的区域,获得沿特征图高度和宽度方向的长程依赖关系。由于 2D 全局池化导致网络丢失特征图的位置信息,CA 选择使用两个 1D 池化操作提取特征图特征,即选择一维全局池化操作分别在特征图的宽和高两个维度计算特征图,得到两个分别包含特征图宽度方向和高度方向信息的注意力特征图,提取输入特征图的长程依赖。

本文在 YOLOv8L 的 Backbone 和 Head 部分中融入 CA 注意力机制,该注意力机制通过 2 个并行的 1D 特征编码过程,捕获特征图的长程依赖关系,加强模型特征图的表示能力。CA 注意力机制网络结构图如图 4。

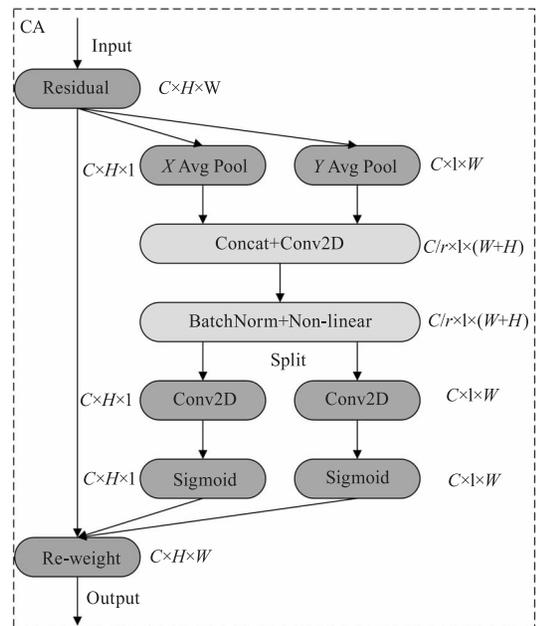


图4 坐标注意力机制网络结构图

Fig. 4 Structure of coordinate attention network

2.2.4 PAN + ASFF 模块

YOLOv8L 模型 Neck 部分的 PAN 结构只是将不同尺度的特征图进行简单的通道拼接,没有考虑

融合特征图时特征信息不一致的问题。针对此问题,本文在 YOLOv8L 的 Neck 部分引入金字塔特征融合策略 ASFF,自适应选择不同尺度特征图中关键的特征信息,提升网络对多尺度目标的检测效果。

ASFF 的结构如图 5 所示,ASFF 的核心理念是通过添加中间卷积层,自适应地获得特征图的融合空间权重,具体可以划分为两个步骤:恒等缩放和自适应融合。恒等缩放:1/2 下采样操作,使用卷积核大小为 3×3 步长为 2 的卷积实现;1/4 下采样操作,使用卷积核大小为 3×3 步长为 2 的卷积以及步长为 2 的池化卷积共同实现。上采样操作,使用双线性插值方法。自适应特征融合:融合后特征图某一位位置 (i, j) 处的向量为三个特征图 (i, j) 处向量的加权融合。

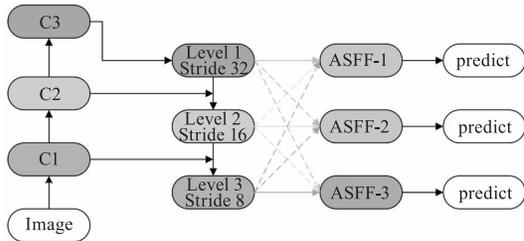


图 5 自适应空间特征融合网络结构图

Fig. 5 Structure of adaptively spatial feature fusion

本文在融合 ASFF 结构时,对其做了一定的修改,以减小模型参数数量和降低增加的推理开销。YOLOv8L-r 的 Neck 部分的输入为 Backbone 三个不同尺度的特征图,记为 C3, C4, C5, 对三个不同级别的特征图的处理过程如下: C5 通过上采样操作与 C4 融合得到特征图 $C4_1$, $C4_1$ 通过上采样与 C3 融合得到特征图 $C3_1$; $C3_1$ 通过下采样操作与 $C4_1$ 融合得到特征图 $C4_2$, $C4_2$ 通过下采样操作与 C5 融合得到特征图 $C5_2$ 。在特征融合阶段每次只有两个不同尺度的特征图进行融合,所以本文使用的 ASFF 结构在融合特征时只处理两个不同尺度的特征图。修改后的 ASFF 结构图如图 6。

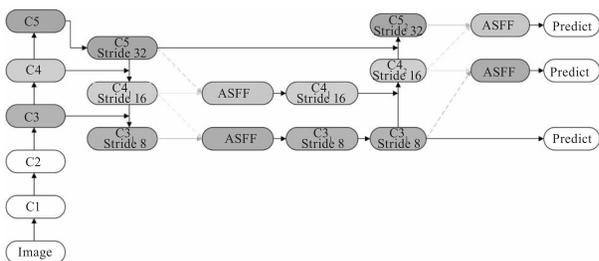


图 6 修改后的自适应空间特征融合网络结构图

Fig. 6 Structure of modified adaptively spatial feature fusion

3 实验结果与分析

3.1 实验环境

为评估所提改进 YOLOv8L-r 模型的性能,在 DOTA 多目标数据集上进行训练和测试。实验使用 NVIDIA RTX3090 显卡, Linux 操作系统, Python3.7, CUDA11.3 与 Paddle-Paddle Detection 框架。

3.2 实验数据集与处理

DOTA^[9] 是面向目标检测的大规模遥感数据集,包含 15 个类别, 2806 张大小约为 4000×4000 像素的航拍图像和 188282 个具有各种尺寸、方向和形状的实例,标注方式分为水平和旋转两种方式。DOTA 数据集的图片尺寸较大,直接以原始尺寸的图片作为网络的输入,难以训练,因此一般需要对 DOTA 数据集进行切割分散处理。在本文中,将数据集中原始图像裁剪为 1024×1024 大小,为避免裁剪时边缘信息的丢失,裁剪时设置重叠像素为 256 像素。

3.3 实验参数设置

输入图像大小为 1024×1024 , 训练中使用动量为 0.9, 权重衰减为 5×10^{-4} 的随机梯度下降 (SGD)。学习率为 0.008, batch size 大小为 2, 迭代次数设为 80 epoch。

3.4 评价标准

在网络训练过程中,采用平均精度均值 (mean Average Precision, mAP) 来评估模型的性能,当 IOU 值大于 0.5 时,将生成的对应 anchor 作为真正的正实例 (True Positive, TP), 当 IOU 值小于等于 0.5 时,将生成的对应 anchor 作为假的正实例 (False Positive, FP), 将没有被检测到的真实实例记为错误的负实例 (False Negative, FN)。mAP 指标综合考虑了查准率 (Precision) 和查全率 (Recall) 两个评价指标,反映了模型在数据集上的精度性能高低。具体 mAP 值的计算方式为:

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

式中, c 表示检测目标的类别数量; i 为目标类别索引。AP 值是坐标轴与查准率和查全率围成的面积, 即 $AP = \int_0^1 p(r) dr$, AP 值可以综合判断某一类的查准率和查全率。查准率和查全率的计算方式为:

$$P_{\text{precise}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (2)$$

$$P_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (3)$$

式中, N_{TP} 为真正正实例的数量; N_{FP} 为假正实例的数量; N_{FN} 假负实例的数量。查准率体现模型预测的所有正样本中真正实例所占的比例, 查全率体现模型正确预测的正样本占数据集中正样本的比例。在检测速度方面采用模型的参数量 (Params) 和浮点运算次数 (Floating Point Operations, FLOPs) 为评价网络检测性能的指标。

3.5 消融实验

为验证本文所提出 YOLOv8L-r 模型各项改进的有效性, 做了多组消融实验, 在同样的条件下采用 DOTA 数据集进行训练和测试。消融实验结果如表 1 所示。

表 1 各模块消融实验结果

Tab. 1 Comparison of ablation experiments of all modules

Group	Model	mAP/ %	Parameters /M	FLOPS /G
G1	基准模型	70.32	50.55	268.07
G2	+ 解耦的角度预测头	70.77 (+0.45)	50.66	268.70
G3	+ 坐标注意力机制	72.85 (+2.08)	51.98	270.62
G4	+ 自适应特征融合	73.85 (+1.00)	53.34	272.65

消融实验具体安排如下: 第一组实验是基准模型的检测实验, 即在 YOLOv8L 的模型基础上, 增加一个角度预测参数。基准模型的 mAP 达到了 70.32; 第二组实验是使用改进的解耦的角度预测头, 分开提取角度回归参数与定位回归参数的特征, 通过一个简单的设计, 将 mAP 提升了 0.45 个百分点; 第三组实验在第二组实验的基础上引入了坐标注意力机制 CA Layer, 分别在 Backbone 每个阶段的尾部以及 Head 部分添加了 CA 模块, 在模型开销增

表 2 不同算法在 DOTA 数据集结果对比

Tab. 2 Comparison of results of different algorithms on DOTA data

Method	PL	BD	BR	GTF	SV	LV	SH	TC	BC	ST	SBF	RA	HA	SP	HC	mAP/%
PIoU ^[10]	80.90	69.70	24.10	60.20	38.30	64.40	64.80	90.90	77.20	70.40	46.50	37.10	57.10	61.90	64.00	60.50
RoI Trans ^[11]	88.64	78.52	43.44	75.92	68.81	73.68	83.59	90.74	77.27	81.46	58.39	53.54	62.83	58.93	47.67	69.56
CAD-Net ^[12]	87.80	82.40	49.40	73.50	71.10	63.50	76.60	90.90	79.20	73.30	48.40	60.90	62.00	67.00	62.20	69.90
G-Rep ^[13]	88.89	74.62	43.92	70.24	67.26	67.26	79.80	90.87	84.46	78.47	54.59	62.60	66.67	67.98	52.16	70.59
DRN ^[14]	88.91	80.22	43.52	63.35	73.48	70.69	84.94	90.14	83.85	84.11	50.12	58.41	67.62	68.60	52.50	70.70
DAL ^[15]	88.68	76.55	45.08	66.80	67.00	76.76	79.74	90.84	79.54	78.45	57.71	62.27	69.05	73.14	60.11	71.44
R ³ Det ^[16]	88.76	83.09	50.91	67.27	76.23	80.39	86.72	90.78	84.68	83.24	61.98	61.35	66.91	70.63	53.94	73.79
CenterMap ^[17]	88.88	81.24	53.15	60.65	78.62	66.55	78.10	88.83	77.80	83.61	49.36	66.19	72.10	72.36	58.70	71.74
Ours	88.60	80.06	54.48	67.35	79.19	73.14	87.52	90.87	85.70	84.11	56.53	58.95	75.05	71.44	54.78	73.85

加较小的情况下, mAP 提升了 2.08 个百分点; 第四组实验在第三组实验的基础上, 改进了网络 Neck 阶段特征融合方式, 将 ASSF 模块与路径融合网络 PAN 模块结合, 使得网络能更有效的融合多尺度特征图信息, 将 mAP 提升了 1.00 个百分点。

为了验证本文在 YOLOv8L 模型基础上改进的 YOLOv8L-r 模型的有效性, 将原 YOLOv8L 算法与改进之后的算法在 DOTA 数据集上的检测效果进行对比, 为了避免实验的偶然性, 展示了多种环境下的对比效果图, 结果如图 7 所示。从图中可以看出, 原 YOLOv8L 算法存在误检和错检、漏检等问题, 改进之后的算法的检测效果有了明显的改善。

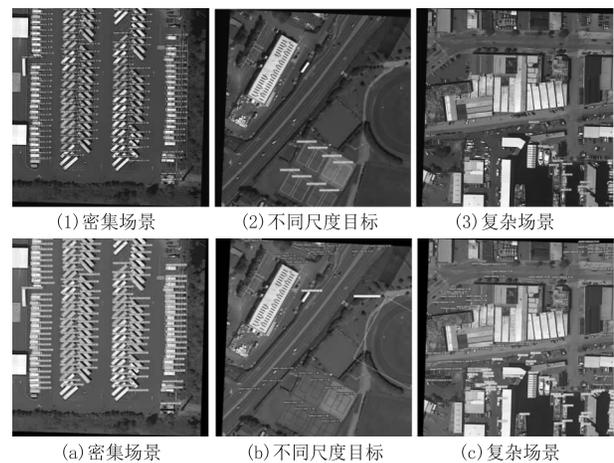


图 7 YOLOv8L 与改进算法检测效果对比图

Fig. 7 Comparison of detection effect between YOLOv8L and improved algorithm

3.6 与其他算法对比

为了进一步验证提出的 YOLOv8L-r 算法的检测效果, 将其与当前主流的一些旋转目标检测算法在 DOTA 数据集上的效果进行对比, 具体实验结果如表 2 所示。

表 2 实验的结果表明,与当前主流的旋转目标检测算法相比,所提出的改进算法 YOLOv8L-r 在 DOTA 数据集上获得了不错的效果,能有效提升遥感图像旋转目标检测精度。

4 结 语

本文对复杂背景下遥感图像的检测问题作了分析,针对具密集排列、尺寸不一、目标数量多、背景复杂等特点的遥感图像检测难的问题,使用当前先进的目标检测算法 YOLOv8L 为基础模型,搭建了适用于旋转检测的改进版 YOLOv8L-r。在改进网络结构和优化角度参数回归两个方面对 YOLOv8L 进行改进。改进网络结构方面通过在 YOLOv8L 的 Backbone 部分和 Head 部分中引入坐标注意力机制,增强了模型对目标检测中长视觉特征的提取能力,抑制了无关的背景信息,让模型给与目标更多关注;在 YOLOv8L 的 Neck 部分引入自适应空间特征融合模块 ASFF,将 ASFF 模块与路径聚合网络 PAN 结合,减少特征金字塔融合不同尺度特征信息时的不一致问题,提高了模型的旋转目标的检测精度。对于优化角度回归参数方面,在网络的 Head 部分使用一个单独的预测分支提取目标的角度特征,避免目标的定位参数特征与角度参数特征相互干扰,有效的提升了模型的检测效果。本研究同时也提供了一种通用目标检测算法,即水平目标检测算法应用于遥感图像旋转检测的思路,具有一定的通用性。

参考文献:

- [1] Wang Wenxia,Zhang Wen,He Kai. Research and application of object detection algorithm based on bimodal feature enhancement [J]. *Laser & Infrared*, 2023, 53 (9): 1364 - 1374. (in Chinese)
王文霞,张文,何凯. 基于双模态特征增强的目标检测算法研究与应用[J]. *激光与红外*, 2023, 53(9): 1364 - 1374.
- [2] Feng Changfeng, Wang Chunping, Fu Qiang, et al. Survey of object detection in optical remote sensing images based on deep learning [J]. *Laser & Infrared*, 2023, 53 (9): 1309 - 1319. (in Chinese)
冯长峰,王春平,付强,等. 基于深度学习的光学遥感图像目标检测综述[J]. *激光与红外*, 2023, 53 (9): 1309 - 1319.
- [3] Yang X, Yang J, Yan J, et al. Scrdet: towards more robust detection for small, cluttered and rotated objects [C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 8232 - 8241.
- [4] Qian W, Yang X, Peng S, et al. Learning modulated loss for rotated object detection [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(3): 2458 - 2466.
- [5] Yang X, Yan J. Arbitrary-oriented object detection with circular smooth label [C]// *Computer Vision-ECCV 2020*, 2020: 677 - 694.
- [6] Yang X, Zhou Y, Zhang G, et al. The KFIOU loss for rotated object detection [J]. *arXiv*, 2022: 2201, 12558.
- [7] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021: 13713 - 13722.
- [8] Liu S, Huang D, Wang Y. Learning spatial fusion for single-shot object detection [J]. *arXiv*, 2019: 1911, 09516.
- [9] Xia G S, Bai X, Ding J, et al. DOTA: a large-scale dataset for object detection in aerial images [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 3974 - 3983.
- [10] Chen Z, Chen K, Lin W, et al. Piou loss: towards accurate oriented object detection in complex environments [C]// *Computer Vision-ECCV 2020*, 2020: 195 - 211.
- [11] Yang X, Yan J. On the arbitrary-oriented object detection: Classification based approaches revisited [J]. *International Journal of Computer Vision*, 2022, 130(5): 1340 - 1365.
- [12] Zhang G, Lu S, Zhang W. CAD-Net: a context-aware detection network for objects in remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(12): 10015 - 10024.
- [13] Hou L, Lu K, Yang X, et al. G-rep: Gaussian representation for arbitrary-oriented object detection [J]. *Remote Sensing*, 2023, 15(3): 757.
- [14] Pan X, Ren Y, Sheng K, et al. Dynamic refinement network for oriented and densely packed object detection [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 11207 - 11216.
- [15] Lang S, Ventola F, Kersting K. Dafne: a one-stage anchor-free deep model for oriented object detection [J]. *arXiv*, 2021: 2109. 06148.
- [16] Yang X, Yan J, Feng Z, et al. R3det: Refined single-stage detector with feature refinement for rotating object [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(4): 3163 - 3171.
- [17] Wang J, Yang W, Li H C, et al. Learning center probability map for detecting objects in aerial images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(5): 4307 - 4323.