基于尺度不变特征融合的轻量级遥感图像旋转目标检测算法

付 博[1,2,3,4]，何月顺[1]，陈 杰[1]，陈志高[1,3,4]，熊凌龙[1]

（1.东华理工大学 测绘与空间信息工程学院，南昌 330013；2.江西水利电力大学 电气工程学院，南昌 330099；3.东华理工大学自然资源部环鄱阳湖区域矿山环境监测与治理重点实验室，南昌 330013；4.江西省测绘地理信息工程技术研究中心，南昌 330025）

摘 要：针对轻量化遥感图像旋转目标检测中因计算量受限导致特征提取能力下降、回归不稳定而影响检测精度的问题，提出了基于尺度不变特征融合的轻量级遥感图像旋转目标检测算法。在主干网络中，采用自适应下采样（Adown）替换原始下采样方案，以更少的计算成本保留更多关键信息，减少特征损失的同时提升检测精度。在颈部网络中，设计了一种高效的SDI-BiFPN多尺度特征融合模块，结合尺度不变特征融合（SDI）机制与双向特征传递（BiFPN）策略，减少计算量的同时增强多尺度特征表达能力。此外，为提升旋转框回归稳定性，模型引入CSL角度编码策略，并采用LPIoU作为回归损失函数，有效缓解了角度周期性问题，提高了回归精度和检测鲁棒性。在公开遥感数据集DOTA上的实验结果表明，本文方法在保证检测精度的同时，实现了参数量下降43.34%，mAP相比基准模型提升4.5%，达到73.19%。与R^3Det、DAL和CenterMap等主流方法相比，本文方法在轻量化设计下依然保持较好的性能。

关键词：尺度不变；特征融合；轻量级；遥感图像；旋转目标检测

中图分类号：TP391 **文献标志码**：A **文章编号**：1671-5497(2026)06-1695-11

DOI：10.13229/j.cnki.jdxbgxb.20250255

Lightweight remote sensing image rotation target detection algorithm based on scale invariant feature fusion

FU Bo[1,2,3,4], HE Yue-shun[1], CHEN Jie[1], CHEN Zhi-gao[1,3,4], XIONG Ling-long[1]

(1. *School of Surveying and Geoinformation Engineering, East China University of Technology, Nanchang* 330013, *China*; 2. *School of Electrical Engineering, Jiangxi University of Water Resources and Electric Power, Nanchang* 330099, *China*; 3. *Key Laboratory of Mine Environmental Monitoring and Improving around Poyang Lake of Ministry of Natural Resources, East China University of Technology, Nanchang* 330013, *China*; 4. *Jiangxi Province Engineering Research Center of Surveying, Mapping and Geographic Information, Nanchang* 330025, *China*)

收稿日期：2025-03-26.

基金项目：国家自然科学基金地区基金项目（42266006）；江西省核地学数据科学与系统工程技术研究中心开放基金项目（JELRGBDT202204）.

作者简介：付博（1992-），男，讲师，博士研究生.研究方向：变形监测数据处理，遥感图像智能解译.
E-mail：FUBOfubo1992@163.com

通信作者：何月顺（1971-），男，教授，博士.研究方向：大数据与智能信息处理，人工智能.
E-mail：ecutHE@126.com

Abstract: To address the issue of degraded feature extraction capability and unstable regression accuracy in lightweight remote sensing rotational object detection due to computational constraints, this paper proposes a lightweight rotational object detection algorithm based on scale-invariant feature fusion. In the backbone network, an adaptive downsampling (Adown) module replaces the conventional downsampling strategy, effectively preserving more critical information with lower computational cost, reducing feature loss while improving detection accuracy. In the neck network, a high-efficiency SDI-BiFPN multi-scale feature fusion module is designed, integrating the scale-invariant feature fusion (SDI) mechanism and bidirectional feature propagation (BiFPN) strategy, which enhances multi-scale feature representation while reducing computational complexity. Furthermore, to improve the stability of rotated bounding box regression, the model incorporates the CSL (Circular Smooth Label) angle encoding strategy and adopts LPIoU (Logarithmic Polar IoU) as the regression loss function, effectively mitigating the periodicity issue in angle regression, thus improving regression accuracy and detection robustness. Experimental results on the public DOTA remote sensing dataset demonstrate that the proposed method achieves a 43.34% reduction in model parameters while maintaining detection accuracy, and improves mAP by 4.5% over the baseline model, reaching 73.19%. Additionally, in comparison with state-of-the-art methods such as R^3Det, DAL, and CenterMap, the proposed approach maintains competitive detection performance while achieving a lightweight design.

Key words: scale invariance; feature fusion; lightweight; remote sensing image; rotation object detection

0 引 言

遥感图像中的目标往往具有不同的尺度、方向和排列方式,特别是在旋转目标检测任务中,传统的基于矩形边界框的目标检测方法已无法满足高精度检测的需求[1,2]。旋转目标检测,即能准确识别并定位具有任意朝向的目标,在航空影像分析、环境监测、城市规划、自动驾驶等多领域具有广泛的应用前景。然而,遥感图像旋转目标检测面临诸多挑战。一方面,遥感图像中的目标可能因拍摄角度、光照条件、遮挡等因素导致特征不明显,增加了检测的难度;另一方面,遥感图像中的目标往往具有多样的尺度和方向,传统目标检测方法难以有效捕捉这些特征,导致检测精度受限。为提高遥感图像旋转目标检测的精度和效率,满足实际应用的需求,众多学者对此展开研究。

Nie等[3]提出了一种轻量级YOLOv8变种,在特征融合阶段加入小目标检测层,并采用小尺度特征融合模块提升多尺度特征的传递能力,从而提高小目标检测精度,同时减少计算量。但该方法主要优化小目标检测,在旋转目标回归方面缺乏深入研究,仍然采用传统IoU作为边界框损失,未能有效缓解角度周期性问题,导致旋转目标检测的稳定性较差。韩慧妍等[4]提出了一种基于YOLOv8L的旋转目标检测方法,在检测头部分增加解耦角度预测模块,并结合坐标注意力机制抑制噪声,同时在特征融合阶段引入自适应空间特征融合模块,以优化不同尺度特征的融合,尽管该方法提升了旋转目标的检测精度,但计算复杂度较高,不利于轻量化应用。刘冰冰等[5]针对船舰遥感图像检测,提出了一种基于改进YOLOv5s的旋转目标检测方法,该方法优化主干网络的卷积结构,以减少跨步卷积导致的细粒度信息丢失,同时引入DCNv3可变形卷积,提高不规则目标的特征提取能力,并在颈部网络中融合浅层特征信息,缓解多次卷积操作导致的细节信息损失,但该方法计算复杂度相对较高。牛为华等[6]提出了一种基于改进YOLOv5的轻量化旋转目标检测方法YOLOv5s-R,在YOLOv5s基础上添加角度参数,使水平检测框转换为旋转检测框,并结合环形圆滑标签(CSL)规避角度回归的周期性问题,同时引入高效通道注意力机制优化特征提取能力。该方法在检测精度和计算效率上有所优化,但特征融合策略较为简单,未能充分利用多尺度信息提升检测能力。

尺度不变特征变换(Scale-Invariant feature transform, SIFT)作为一种经典的特征提取技术,已在图像匹配、物体识别、三维重建等多种视觉任务中展现出强大的鲁棒性。SIFT算法能在

不同尺度、旋转、光照变化及一定程度的视角变化下,稳定可靠地检测并描述图像中的关键特征点,这对于遥感图像旋转目标检测任务具有重要意义。通过引入尺度不变特征,可以增强算法对目标尺度和旋转变化的适应性,提高检测精度。同时,考虑到遥感图像处理的实时性和高效性需求,轻量级算法的设计成为当前研究的热点。轻量级算法能够在保证检测精度的同时,降低计算复杂度和存储需求,适用于资源受限的环境。因此,本文结合尺度不变特征融合和轻量级算法设计,进行遥感图像旋转目标检测。

1　YOLOv8-BASCL 模型

本文算法以 YOLOv8-OBB 为基础网络,针对遥感图像旋转目标检测的特点,在 CSPDarknet 骨干网络中优化下采样策略和特征融合方式,以提升检测精度并降低计算成本。首先,在骨干网络中,采用自适应下采样(AdownSample)模块,优化多尺度信息提取能力,减少特征损失,使模型在检测小目标时更具优势;其次,在颈部网络中,设计 SDI-BiFPN 轻量化特征融合模块,结合尺度分布不变性(SDI)机制与双向特征金字塔(BiFPN)[7],以更优的特征传递方式减少计算量,同时增强多尺度特征的表达能力;最后,为优化旋转框回归,结合 CSL 角度编码策略解决角度周期性问题,并采用 LPIoU 损失函数作为回归优化策略,提高旋转框的稳定性和检测鲁棒性。改进后网络架构如图 1 所示。

1.1　SDI-BiFPN 轻量化特征融合模块

在遥感图像目标检测任务中,多尺度特征融合对于提高检测精度至关重要[8,9]。传统的特征金字塔(FPN)仅采用自上而下的信息传递方式,难以充分利用不同尺度的特征信息,而 PANet(Path aggregation network)尽管增强了特征流动,但计算复杂度较高,如图 2 所示。为此,本文构建了一种轻量化的特征融合结构 SDI-BiFPN,在降低计算量的同时,增强多尺度特征的表达能力[10,11],提高旋转目标检测的精度和鲁棒性。

SDI-BiFPN 结合双向特征金字塔(BiFPN)结构和尺度分布不变性(SDI)机制,允许特征在不同尺度之间进行更高效的交互[12]。如图 3 所示,BiFPN 通过增加横向连接,使不同尺度的特征图能够进行更深层次的信息融合,从而优化目标特征的表达能力。其计算过程可以表示为:

$$F_l^{\text{out}} = w_1 \cdot F_l^{\text{in}} + w_2 \cdot U(F_{l+1}^{\text{in}}) + w_3 \cdot D(F_{l-1}^{\text{in}}) \tag{1}$$

式中:$U(\cdot)$和$D(\cdot)$分别表示上采样和下采样操作;w_1、w_2、w_3是可学习的权重参数,使不同尺度的特征融合权重可以自适应调整,从而保证多尺度信息的合理分配,提高特征表达能力。

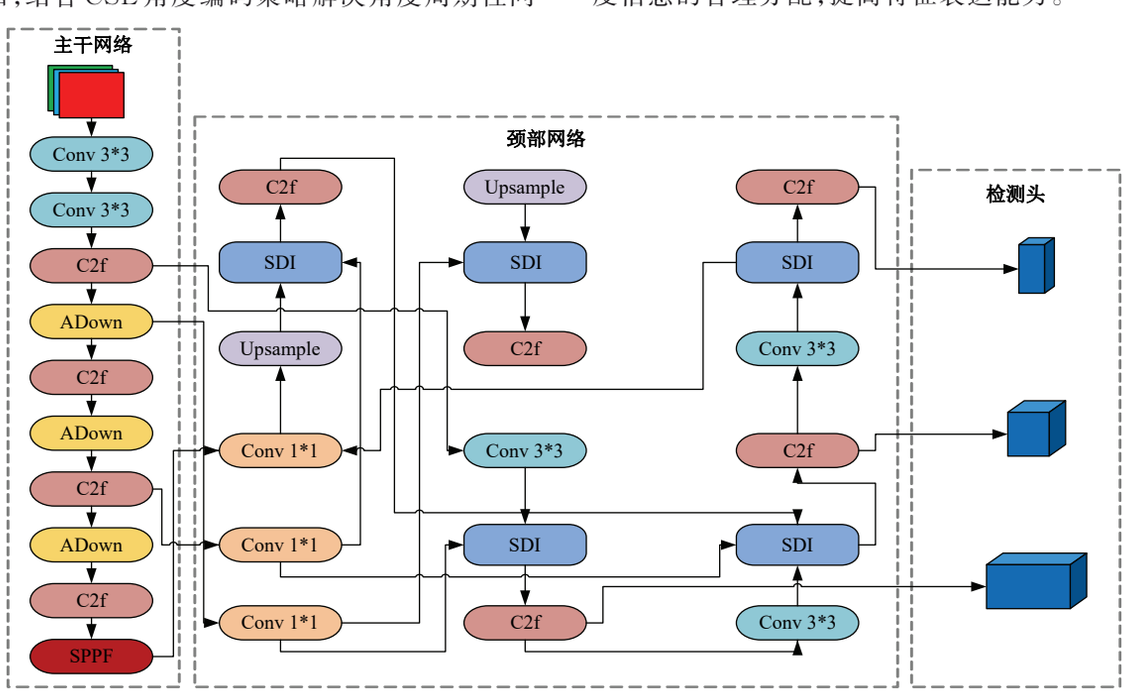

图 1　本文模型网络结构图

Fig. 1　Network structure diagram of the model in this article

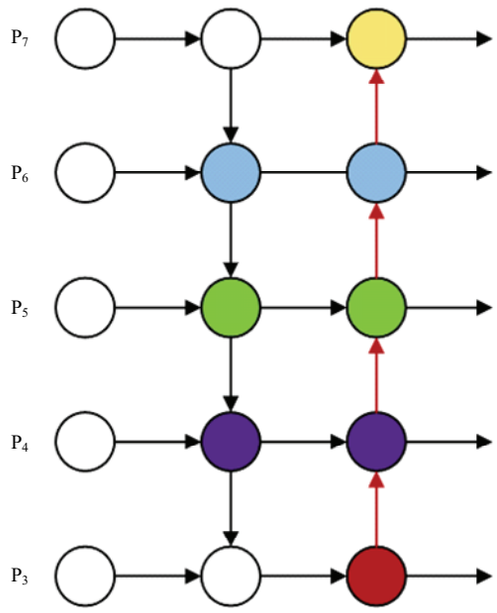

图2 PANet结构

Fig. 2 PANet structure

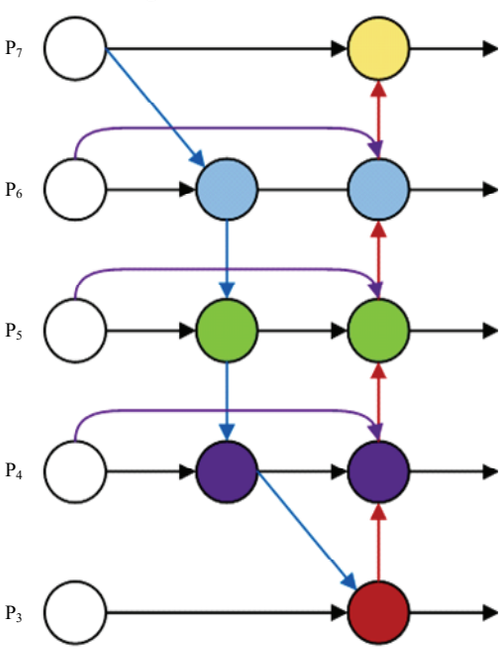

图3 BiFPN结构

Fig. 3 BiFPN structure

为进一步优化特征的稳定性,本文在BiFPN结构中引入尺度分布不变性(SDI)机制。SDI通过在特征提取过程中引入空间注意力(Spatial attention)和通道注意力(Channel attention)机制,使模型能自适应调整不同空间位置和通道的信息权重,从而提高检测精度。设定特征图的通道维度为C,则经过SDI处理后的特征图F'可表示为:

$$F'=\sigma(W_s*F+W_c*F) \tag{2}$$

式中:W_s为空间注意力权重;W_c为通道注意力权重;$\sigma(\cdot)$为Sigmoid激活函数。

通过上述操作,关注特征图的空间和通道维度[13,14],可以提高网络对不同尺度目标的区分能力,同时减少冗余计算,提高模型的整体检测性能。

图4展示了SDI机制的具体结构,不同尺度的特征经过SDI模块后,可以通过空间注意力、通道注意力以及平滑卷积(SmoothConv)进行融合,使得模型能更稳定地捕捉不同尺度目标,提高旋转目标的检测精度[15,16]。其中,平滑卷积(SmoothConv)采用3×3及1×1卷积核,步长(stride)设为1,以确保特征信息在不同尺度间的平滑传递,同时降低特征损失,提高特征一致性。在特征传输过程中,SDI模块结合上采样(UpSample)、下采样(DownSample)和恒等映射(IdentityMap)进行尺度调节,确保不同层级特征的有效交互,最终提高检测的稳定性和鲁棒性。通过SDI-BiFPN的优化,本文提出的模型能在轻量化设计的基础上,充分利用多尺度信息,减少计算资源消耗的同时提高检测精度。

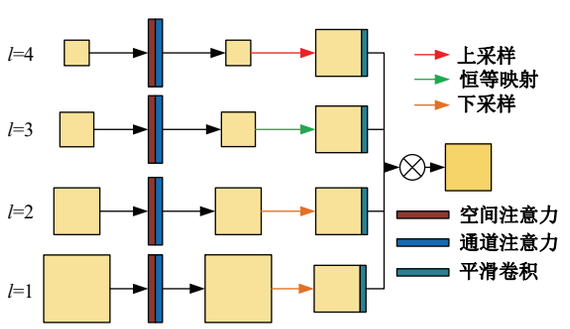

图4 SDI机制的具体结构

Fig. 4 Specific structure of SDI mechanism

1.2 Adown 自适应下采样

在遥感目标检测任务中,主干网络的下采样策略对特征提取至关重要,尤其在旋转目标和小目标检测场景中,传统下采样方法(如最大池化和步长卷积)可能导致关键信息的丢失,影响检测精度[17]。为此,本文引入自适应下采样(Adown)机制,采用多路径特征提取方式,在降低计算量的同时增强不同尺度目标的特征表达能力,如图5所示。

Adown采用双分支结构,输入特征图F被分为两个并行路径。第一个路径通过平均池化(AVG Pooling)获取全局信息,第二个路径通过最大池化(MAX Pooling)关注局部显著区域。随后,两条路径的特征分别经过不同的卷积操作进

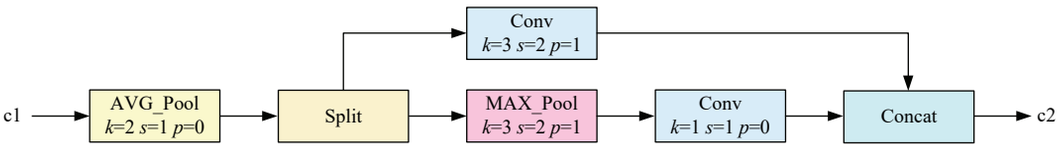

图 5　自适应下采样(Adown)机制

Fig. 5　Adaptive downsampling (Adown) mechanism

行信息提取,并在最终阶段进行融合。其计算过程可表示为:

$$\begin{cases} F_{avg}=\mathrm{AvgPool}(F,k=2,s=1,p=0) \\ F_{max}=\mathrm{MaxPool}(F,k=3,s=2,p=1) \\ F_{conv1}=\mathrm{Conv}(F_{avg},k=3,s=2,p=1) \\ F_{conv2}=\mathrm{Conv}(F_{max},k=1,s=1,p=0) \\ F_{out}=\mathrm{Concat}(F_{conv1},F_{conv2}) \end{cases} \tag{3}$$

式中:k为卷积核大小;s为步长;p为填充;Conv(•)表示卷积操作;Concat(•)代表通道拼接操作。

这种融合机制确保了旋转目标的关键特征在下采样过程中不被丢失,同时减少计算冗余,提高模型效率。

1.3　CSL 角度编码策略

在遥感图像旋转目标检测中,目标的角度回归面临周期性问题,即当目标角度从179°变为−179°时,导致梯度不连续,影响模型收敛稳定性。为缓解这一问题,本文采用环形平滑标签(Circular smooth label,CSL)角度编码策略,通过高斯平滑分布使角度回归更加平滑,提高旋转目标检测的稳定性。

如图6所示,CSL采用环形编码方式,避免角度数值突变带来的梯度不连续问题。具体而言,

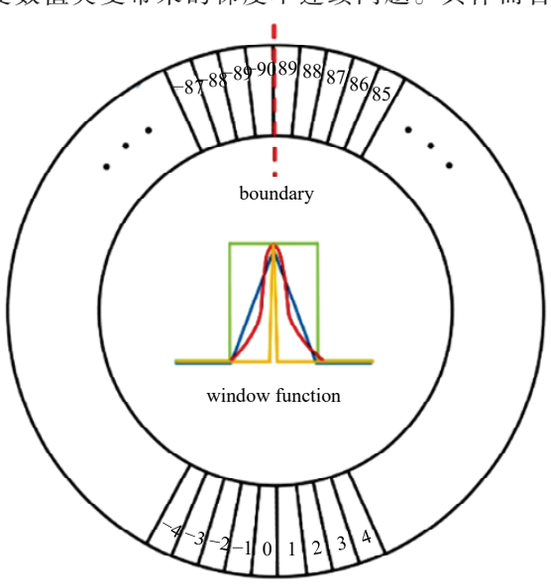

图 6　环标签编码策略

Fig. 6　Ring Label Encoding Strategy

设目标真实角度为θ,传统方法采用直接回归:

$$\angle_{angle}=\|\theta_p-\theta_{gt}\| \tag{4}$$

式中:θ_p为预测角度,但在角度接近180°或−180°时,该损失函数会产生较大的梯度波动;θ_{gt}为标注的真实角度值。

CSL通过引入高斯平滑分布,使相邻角度的梯度变化更为平稳,其计算公式如下:

$$\hat{y}(\theta)=\exp\left(-\frac{(\theta-\theta_{gt})^2}{2\sigma^2}\right) \tag{5}$$

式中:$\hat{y}(\theta)$为角度θ处的平滑分布;σ控制平滑程度。

该方法在角度周期边界(如89°和−89°)仍能保持合理的梯度更新,避免角度数值的不连续性对模型训练造成干扰。通过CSL角度编码策略,模型能够在旋转目标检测任务中更准确地预测目标角度,并提高在复杂场景下的检测性能。

1.4　LPIoU 损失函数

传统交并比(Intersection over Union,IoU)损失在旋转目标检测任务中存在局限性,主要表现为:①角度不敏感,即IoU仅关注目标框的区域重叠,无法正确反映角度偏差;②尺度不平衡,当目标框尺寸差距较大时,IoU对小目标的梯度贡献较小。为此,本文采用极坐标对数IoU(Logarithmic Polar IoU,LPIoU)损失函数,在极坐标空间下计算IoU,以增强旋转框的匹配度。预测框和真实框分别表示为$B_p=(x_p,y_p,w_p,h_p,\theta_p)$和$B_t=(x_t,y_t,w_t,h_t,\theta_t)$,LPIoU计算过程如下:

$$\mathrm{LPIoU}=1-\frac{I(B_p,B_t)}{U(B_p,B_t)}-\lambda\log(1+|\theta_p-\theta_t|) \tag{6}$$

式中:$I(B_p,B_t)$和$U(B_p,B_t)$分别为预测框与真实框的交集面积和并集面积;λ为角度偏差调节系数,确保角度误差对损失的贡献合理。

LPIoU通过引入角度对数惩罚项,使模型在计算IoU时同时优化角度回归,提高旋转目标检

测的稳定性,特别是在密集目标和高旋转目标的场景下,能提升检测性能。

2 实验与分析

2.1 数据集介绍

本实验采用DOTA公开遥感图像目标检测数据集进行模型性能评估。其中,DOTA(Dataset for object detection in aerial images)是一个高分辨率遥感图像数据集,包含15类目标,如飞机、船舶、车辆等,其标注方式为旋转边界框(OBB)。DOTA数据集包含多个版本,本实验选用DOTA-v1.0,其中训练集、验证集和测试集分别包含1 400、458和937张图像,分辨率从800×800到4 000×4 000不等。

2.2 评价标准

为了全面评估模型的检测性能,本实验采用以下指标进行分析:

P(Precision,精确率):衡量预测的目标框中正确检测目标的比例,定义为:

$$P=\frac{TP}{TP+FP} \tag{7}$$

式中:TP为正确检测的目标数;FP为错误检测的目标数。

R(Recall,召回率):衡量所有真实目标中被正确检测的比例,定义为:

$$R=\frac{TP}{TP+FN} \tag{8}$$

式中:FN为未被检测出的目标数。

mAP(Mean Average Precision,均值平均精度):表示所有类别的平均精度,计算公式如下:

$$mAP=\frac{1}{N}\sum_{i=1}^{N}AP_i \tag{9}$$

式中:N为目标类别数;AP_i为第i类的平均精度。

GFLOPS(Giga Floating-point Operations Per Second):衡量模型的计算复杂度,即每秒执行的浮点运算次数,GFLOPS越小,模型计算成本越低。Params(参数量):表示模型的总参数数量,通常用于衡量模型的复杂度和存储需求。

本实验主要考察不同方法在DOTA数据集上的mAP、精确率(P)、召回率(R)、GFLOPS以及参数量(Params),以全面评估检测精度和模型轻量化性能。

2.3 实验设定

本实验基于Ubuntu 20.04操作系统搭建,配备两块NVIDIA RTX 3080 GPU以加速模型训练。深度学习框架选用PyTorch 1.8.0,结合CUDA 11.3并行计算引擎与CUDNN 8.3.4加速库提升运算效率。实验中,输入图像经归一化预处理,并引入随机旋转、尺度缩放、水平/垂直翻转等数据增强技术增强模型泛化性能。针对不同数据集采用差异化预处理策略:DOTA数据集裁剪为1 024×1 024分辨率,DIOR-R数据集则使用800×800尺寸进行训练。训练配置采用初始学习率0.001,结合余弦退火学习率调度策略,优化器选用带动量为0.9和权重衰减为0.000 5的SGD算法,设置batch size为16,通过300轮迭代训练后选取最优模型进行性能评估。

实验过程中,算法的参数设置如表1所示。为确保公平对比,所有模型均在相同数据集和参数设定下进行训练,并在DOTA和DIOR-R数据集上进行评估,以验证改进模型的检测精度和计算效率。

表1 算法的参数设置

Table 1 Parameters setting of the algorithm

	参数名称	参数值
颈部网络配置	SDI-BiFPN层数	3
	尺度不变因子	0.5
旋转框回归配置	CSL角度编码范围	[−π, π]
	CSL编码分辨率	180
	LPIoU损失函数IoU阈值	0.5
	LPIoU损失函数权重	1.0

2.4 消融实验

为评估本文所提各改进模块对遥感图像中旋转目标检测任务的有效性,实验以DOTA数据集为基准,在统一的训练配置与硬件环境下,采用精确率(P)、召回率(R)、均值平均精度(mAP)作为性能评估指标,设计消融实验。以分析SDI-BiFPN轻量化特征融合模块、自适应下采样(Adown)、CSL角度编码策略和LPIoU旋转框回归损失对最终检测性能的影响,实验结果如表2所示。

相比于基础模型YOLOv8-OBB,SB-YOLOv8仅加入SDI-BiFPN轻量化特征融合模块,使模型参数量从11.1 M下降至7.5 M,GFLOPS从28.5 G下降至25.8 G,mAP提升1.9%(68.6%~70.5%),精确率(P)从75.5%提升至76.0%,召回率(R)从65.8%提升至66.7%。实验结果表明,SDI-BiFPN通过优化多尺度特征融合,使得检测

表 2 各模块消融实验结果

Table 2　Results of ablation experiments for each module

模型	SDI−BiFPN	Adown	CSL	Lpiou	Parms/M	GFLOPS/G	*P*/%	*R*/%	*mAP*/%
YOLOv8-OBB	−	−	−	−	11.1	28.5	75.5	65.8	68.6
SB-YOLOv8	√				7.5	25.8	76.0	66.7	70.5
SBA-YOLOv8	√	√			6.4	23.8	76.1	67.2	71.3
SBAC-YOLOv8	√	√	√		6.4	24.6	76.3	69.1	72.4
SBACL-YOLOv8	√	√	√	√	6.4	24.6	76.8	69.8	73.1

精度和计算效率均得到提升,同时增强了模型的轻量化特性。

在SDI-BiFPN基础上,SBA-YOLOv8进一步引入Adown自适应下采样,使参数量从7.5M下降至6.4M,GFLOPS由25.8G降低至23.8G,mAP从70.5%提高至71.3%,精确率(*P*)从76.0%提升至76.1%,召回率(*R*)从66.7%提升至67.2%。实验结果表明,Adown能在降低计算复杂度的同时,有效增强模型对旋转目标的检测能力。

在SBA-YOLOv8基础上加入CSL角度编码,得到SBAC-YOLOv8,其*mAP*从71.3%提高到72.4%,召回率提高了1.9%。由于CSL通过高斯平滑角度标签缓解了角度周期性问题,使得模型在回归角度时更加稳定,从而提升了旋转目标检测的性能。

在SBAC-YOLOv8基础上进一步结合LPIoU作为旋转框回归损失,得到完整的SBACL-YOLOv8,mAP提升至73.1%,精确率(*P*)和召回率(*R*)分别提高到76.8%和69.8%。LPIoU通过极坐标对数变换优化旋转目标的IoU计算,使得模型更加精准地学习目标框的位置和角度,提高目标回归的稳定性。

从实验结果来看,各改进模块均对提升模型性能起到了积极作用。其中,SDI-BiFPN主要优化特征融合,提高检测精度并减少计算量;Adown提高了多尺度特征表达能力,优化小目标检测性能;CSL角度编码有效缓解角度周期性问题,使旋转目标回归更加稳定;LPIoU进一步优化旋转框的回归精度,提高了最终的检测性能。最终,本文方法在保持较低计算复杂度的同时,实现了73.1%mAP,相比基础模型YOLOv8-OBB提高了4.5%,验证了改进方法的有效性。为进一步验证本文改进模块的有效性,对YOLOv8-OBB与本文模型的特征响应进行了可视化分析,并通过热力图对比不同方法的目标关注区域。

如图7所示(彩图参见电子版,下同),第二行展示了YOLOv8-OBB的热力图,第三行为本文模型的热力图。对比结果表明,YOLOv8-OBB在特征提取过程中存在较多背景区域的高响应(红色区域分布较散),导致误检较多,同时对小目标和密集目标的检测效果不稳定。相比之下,本文模型在改进后,较好提升了模型的目标聚焦能力,使检测区域的热力图分布更加集中,背景噪声明显减少,目标区域特征更加清晰。

具体而言,在码头、网球场、密集车辆等场景中,YOLOv8-OBB由于多尺度特征融合能力不足,导致热力图中的目标区域响应较弱,而背景区域出现较多无关高响应区域。本文模型通过优化特征融合策略,使高响应区域更加精准地覆盖真实目标,避免了无效区域的干扰,提高了目标检测的稳定性和鲁棒性。此外,本文方法在旋转目标的检测上表现更加精准,热力图显示出更清晰的边界,使得检测框能够更准确地拟合目标轮廓,尤其在小目标和密集场景中展现了更优的检测效果。

2.5　对比实验

为验证本文方法在遥感图像旋转目标检测任务中的有效性,在DOTA数据集上进行了对比实验,并通过*P*-*R*曲线(Precision-recall curve)和*mAP*评分评估检测器的整体性能。

图8所示的*P*-*R*曲线展示了不同类别目标的精确率和召回率分布情况,*P*-*R*曲线表明,本文方法在多个类别上均表现优异,尤其在plane(0.934)、ship(0.893)、large-vehicle(0.870)和tennis-court(0.947)等类别中取得了较高的检测精度。此外,整体*mAP*@0.5达到0.731,表明本文方法在不同类别下均能保持较强的检测能力,尤其在复杂背景和高旋转目标检测任务中具有更稳定的特征提取和目标定位能力。通过进一步分析可以发现,本文方法在小目标和高旋转目标类别上的召回率较传统方法有明显提升,在不同尺度和旋转角度下的检测稳定性得到了增强。

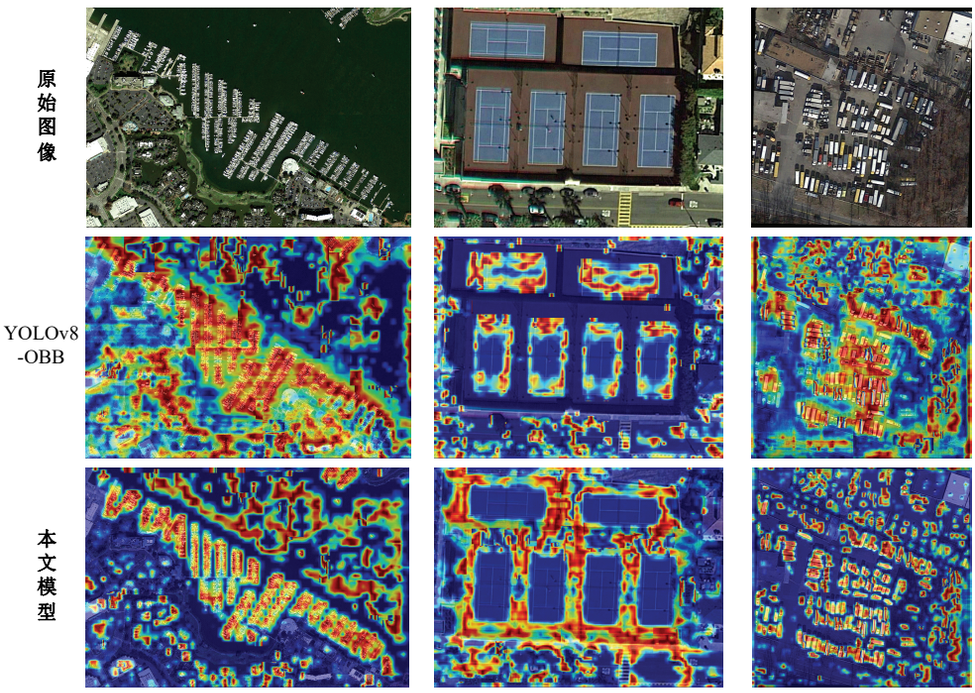

图7 在DOTA数据集中的热力图对比

Fig. 7 Comparison of heat maps in the DOTA dataset

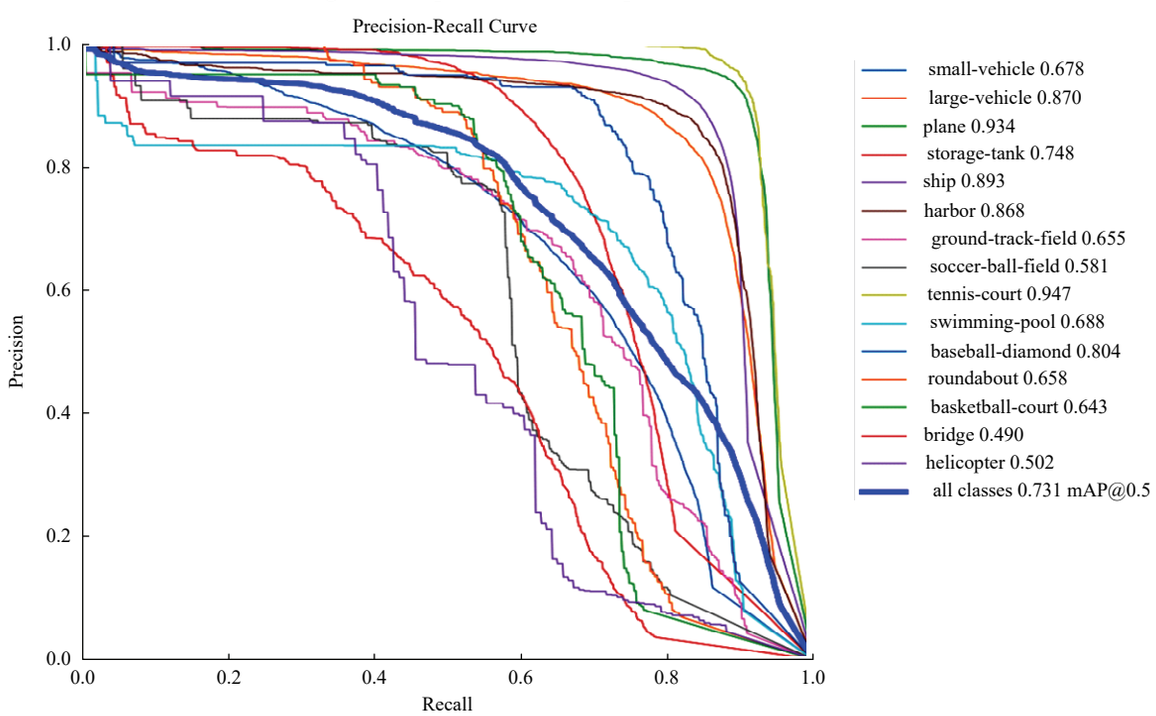

图8 DOTA数据集中本文模型的PR曲线图

Fig. 8 PR curve of our model in the DOTA dataset

为了进一步量化不同方法的检测能力,表3对比了本文方法与当前主流旋转目标检测方法(RoI Trans、G-Rep、DAL、CenterMap、R^3Det)在DOTA数据集上的检测性能。

实验结果表明,本文方法在多个类别上均取得了更优的检测效果,尤其在PL(93.42%)、HA(86.87%)和SH(89.31%)等类别上表现突出。相比于RoI Trans(69.56% *mAP*)、G-Rep(70.59% *mAP*)、DAL(71.44% *mAP*)和CenterMap(71.74% *mAP*),本文方法的整体检测精度更高,同时在多个关键类别上展现了更好的适应性。此外,本文方法的*mAP*达到73.19%,与

表 3 DOTA 数据集上各模型检测精度对比

Table 3　Comparison of detection accuracy of various models on DOTA dataset　%

方法	RA	SP	BR	GTF	SV	ST	SBF	TC	BC	LV	SH	PL	HA	BD	HC	*mAP*
RoI Trans	53.74	58.93	43.44	75.92	68.81	81.46	58.39	90.74	77.27	73.68	83.59	88.64	62.83	78.52	47.67	69.56
G-Rep	62.60	67.98	43.92	70.24	67.26	78.47	54.59	90.87	84.46	67.26	79.80	88.89	66.67	74.62	52.16	70.59
DAL	62.37	73.19	45.08	66.80	67.00	78.45	57.71	90.84	79.45	76.76	79.74	88.68	69.12	76.55	60.11	71.44
CenterMap	66.19	72.36	53.15	60.65	76.78	83.61	49.36	88.83	77.80	76.10	80.10	88.88	72.10	81.24	58.70	71.74
R^3Det	61.35	70.63	50.91	67.27	76.23	83.24	61.98	90.78	84.68	80.25	86.56	88.76	66.91	83.09	53.94	73.51
本文	65.87	68.84	49.09	65.56	67.85	74.87	58.12	94.76	64.37	87.06	89.31	93.42	86.87	80.40	50.23	73.19

R^3Det(73.51%)相比,仅有 0.32% 的微小差距,但在参数量和计算复杂度方面具有更优的轻量化特性,这表明所提出的改进方案在保持较低计算量的同时,仍然具备与最优方法相当的检测精度。结合 *P*-*R* 曲线和对比实验的结果可以得出,本文方法通过优化特征融合、下采样策略和旋转框回归方法,不仅在检测精度上优于多种主流方法,同时在小目标检测、旋转目标回归精度和计算效率等方面展现了较强的优势,证明了本文方法在遥感图像旋转目标检测任务中的有效性和适用性。

2.6　模型效果可视化

为了直观展示本文方法在遥感图像旋转目标检测任务中的检测能力,本文对检测结果进行了可视化分析,并与原始 YOLOv8 方法进行了对比。图 9 和图 10 展示了不同场景下的目标检测结果,其中包括水域区域的码头检测和城市环境中的车辆检测。可视化结果表明,本文方法在旋转目标的精确定位、多目标密集检测和小目标检测方面均表现优异。

在图 9 中,左侧为原始 YOLOv8 方法的检测结果,右侧为本文方法的检测结果。结果表明,本文方法在码头检测任务中,相较于原始方法,检测框更准确地拟合了目标边界,尤其是在长条状目标(如码头和船只)上,检测结果更加贴合目标的真实形态。此外,本文方法在旋转目标的定位上更为精准,有效减少了框与目标之间的错位问题,

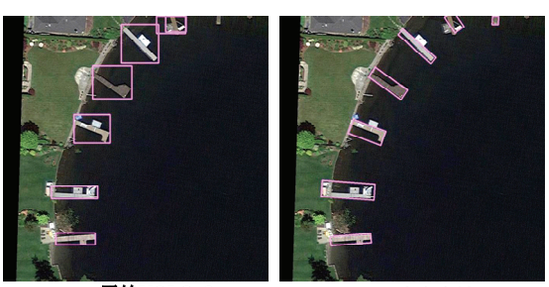

原始YOLOv8　　本文方法

图 9　水域区域的码头检测对比

Fig. 9　Comparison of dock detection in water area



原始YOLOv8　　本文方法

图 10　城市环境中的车辆检测对比

Fig. 10　Comparison of vehicle detection in urban environment

使得检测框的角度与目标方向更加一致,增强了目标的识别准确性。同时,本文方法对目标边界的刻画更加细致,减少了冗余区域的覆盖,提高了目标区域的区分度,进一步提升了检测的精度和可靠性。

在图 10 中,展示了车辆停放区域的大规模检测结果。可以观察到,左侧的原始 YOLOv8 方法在检测过程中存在较多漏检情况,特别是在红色椭圆框标注的区域,多个小型车辆未能正确检测。此外,在红色矩形框标注的区域,检测框分布较为杂乱,部分目标的边界未能正确拟合,甚至出现多个重叠或错位的检测框,影响了检测的整体稳定性。

相比之下,右侧本文方法在引入 CSL 角度编码策略和 LPIoU 旋转框回归后,目标检测框的排列更加规范,旋转角度更符合目标实际朝向,减少了角度预测误差。同时,虽然仍然存在一定的漏检现象,但整体漏检数量显著减少,尤其是在高密度停车场环境下,检测结果更加稳定。此外,本文方法在不同尺度车辆的检测适应性方面表现更优,能够更准确地识别小型车辆,避免因目标尺度较小而导致的误检或漏检。这一对比结果表明,本文方法在优化旋转目标检测方面取得了更好的

效果,特别是在密集目标场景下减少了目标遗漏,提升了旋转框的准确性,验证了改进策略的有效性。

综合可视化结果表明,本文方法在旋转目标检测任务中具有较高的检测精度和适应性,能有效识别不同尺度、不同朝向的目标,并在密集目标场景下保持较好的区分能力。相较于对比方法,检测结果更加精确,旋转框与目标轮廓的匹配程度更高,避免了水平框带来的边界冗余问题。同时,在高密度场景下,目标之间的区分更加清晰,减少了误检与漏检的情况。特别是在小目标检测任务中,本文方法展现出更好的召回率,能有效检测出传统方法容易忽略的细小目标。此外,在不同类型场景中的表现均较为稳定,证明了其在复杂遥感图像环境中的适用性和鲁棒性。

3 结束语

本文提出了一种基于改进YOLOv8的轻量级遥感图像旋转目标检测算法,通过引入SDI-BiFPN轻量化特征融合、Adown自适应下采样、CSL角度编码策略和LPIoU旋转框回归损失等优化策略,显著提升了旋转目标检测的精度,尤其在处理小目标和高旋转目标时表现突出。实验结果表明:该方法在公开数据集上取得了优异的检测性能,同时有效降低了模型的参数量和计算成本,使其适用于资源受限的嵌入式设备和边缘计算平台。然而,在极端复杂背景下的误检率和目标粘连问题仍需进一步优化,且模型的推理效率有待提升以满足更高实时性要求的应用场景。

参考文献:

[1] 刘春娟, 辛钰强, 吴小所, 等. 基于多尺度特征融合的遥感图像变化检测网络[J]. 四川大学学报:自然科学版, 2024, 61(6): 115-125.
Liu Chun-juan, Xin Yu-qiang, Wu Xiao-suo, et al. Remote sensing image change detection network based on multi-scale dense fusion[J]. Journal of Sichuan University (Natural Science Edition), 2024, 61(6): 115-125.

[2] 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.

[3] Nie H, Pang H, Ma M, et al. A lightweight remote sensing small target image detection algorithm based on improved YOLOv8[J]. Sensors, 2024, 24(9): s24092952.

[4] 韩慧妍, 张秀权, 况立群, 等. 基于YOLOv8L遥感图像旋转目标检测[J]. 激光与红外, 2024, 54(9): 1462-1468.
Han Hui-yan, Zhang Xiu-quan, Kuang Li-qun, et al. Rotating object detection of remote sensing image based on YOLOv8L[J]. Laser & Infrared, 2024, 54(9): 1462-1468.

[5] 刘冰冰, 胡耀国, 闫鹏, 等. 改进YOLOv5s算法的遥感图像旋转目标检测[J]. 激光杂志, 2024, 45(12): 49-57.
Liu Bing-bing, Hu Yao-guo, Yan Peng, et al. Improved YOLOv5s algorithm for rotation object detection in remote sensing images[J]. Laser Journal, 2024, 45(12): 49-57.

[6] 牛为华, 郭迅. 基于改进YOLOv8的船舰遥感图像旋转目标检测算法[J]. 图学学报, 2024, 45(4): 726-735.
Niu Wei-hua, Guo Xun. Rotating target detection algorithm in ship remote sensing images based on improved YOLOv8[J]. Journal of Graphics, 2024, 45(4): 726-735.

[7] 李科文, 朱光磊, 王辉, 等. 联合双重注意力机制和双向特征金字塔的遥感影像小目标检测[J]. 遥感学报, 2024, 28(12): 3231-3248.
Li Ke-wen, Zhu Guang-lei, Wang Hui, et al. Joint dual attention mechanism and bidirectional feature pyramid for remote sensing small targets detection[J]. National Remote Sensing Bulletin, 2024, 28(12): 3231-3248.

[8] 李坤亚, 欧鸥, 刘广滨, 等. 改进YOLOv5的遥感图像目标检测算法[J]. 计算机工程与应用, 2023, 59(9): 207-214.
Li Kun-ya, Ou Ou, Liu Guang-bin, et al. Target detection algorithm of remote sensing image based on improved YOLOv5[J]. Computer Engineering and Applications, 2023, 59(9): 207-214.

[9] 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.

[10] 张昊, 刘凤, 谭富祥, 等. 优化特征融合的多尺度遥感图像目标检测方法[J]. 计算机应用与软件, 2024,

41(8): 155-161.
Zhang Hao, Liu Feng, Tan Fu-xiang, et al. Multi-scale remote sensing image target detection method based on optimized feature fusion[J]. Computer Applications and Software, 2024, 41(8): 155-161.

[11] 贾克斌, 何岩, 魏之皓. 融合多尺度特征的高分辨率森林遥感图像分割[J]. 北京工业大学学报, 2024, 50(9): 1089-1099.
Jia Ke-bin, He Yan, Wei Zhi-hao. Fusing multi-scale features for segmentation of high resolution forest remote sensing images[J]. Journal of Beijing University of Technology, 2024, 50(9): 1089-1099.

[12] 李子怡, 曲婷婷, 崇乾鹏, 等. 基于模糊多尺度特征的遥感图像分割网络[J]. 计算机应用, 2024, 44(11): 3581-3586.
Li Zi-yi, Qu Ting-ting, Chong Qian-peng, et al. Remote sensing image segmentation network based on fuzzy multiscale features[J]. Journal of Computer Applications, 2024, 44(11): 3581-3586.

[13] 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.

[14] 齐晶, 胡敏, 张京波. 特征增强的多尺度视觉转换器在遥感图像场景分类中的应用[J]. 航天返回与遥感, 2023, 44(4): 79-87.
Qi Jing, Hu Min, Zhang Jing-bo. Enhanced multi-scale vision transformer for scene classification of remote sensing images[J]. Spacecraft Recovery & Remote Sensing, 2023, 44(4): 79-87.

[15] Hou L, Lu K, Yang X, et al. G-rep: Gaussian representation for arbitrary-oriented object detection[J]. Remote Sensing, 2023, 15(3): 1-24.

[16] 杨玉敏, 廖育荣, 林存宝, 等. 基于轻量化神经网络的空中目标检测算法[J]. 计算机仿真, 2022, 39(7): 70-73.
Yang Yu-min, Liao Yu-rong, Lin Cun-bao, et al. Aerial target detection algorithm based on lightweight neural network[J]. Computer Simulation, 2022, 39(7): 70-73.

[17] Yao G, Zhu S, Zhang L, et al. HP-YOLOv8: high-precision small object detection algorithm for remote sensing images[J]. Sensors, 2024, 24(15): s24154858.