

# 抗干扰注意力赋能的YOLOv8在复杂背景遥感影像中的目标检测

吴文俊, 卞宇晨, 林祉邑, 林佳

闽江大学计算机与大数据学院, 福建 福州

收稿日期: 2026年4月23日; 录用日期: 2026年5月22日; 发布日期: 2026年5月29日

## 摘要

针对复杂场景下遥感目标检测存在的小目标易漏检、特征表征能力弱、检测精度与鲁棒性不足等问题, 研究提出了一种改进的YOLOv8遥感目标检测模型。通过构建PCM像素关系模块增强局部上下文关联, 提升小目标与弱特征目标的表达能力; 设计MultiSEAM多尺度注意力机制, 强化多尺度特征融合并抑制背景噪声; 引入InnerShape-IoU损失函数优化边界框回归, 提高模型收敛性与定位精度。在UCAS-AOD数据集上的实验表明, 所提模型mAP@0.5达96.2%, 与基准模型基本持平, 参数量与推理速度均衡, 在小目标、密集目标及复杂背景下鲁棒性更强。该模型在轻量化前提下实现性能提升, 可为遥感监测、灾害评估、国土资源调查等领域提供有效技术支撑。

## 关键词

遥感目标检测, 改进YOLOv8, 多尺度注意力, 小目标检测

# Target Detection in Remote Sensing Images with Complex Background Based on Anti-Interference Attention Enhanced YOLOv8

Wenjun Wu, Yuchen Bian, Zhiyi Lin, Jia Lin

School of Computer and Big Data, Minjiang University, Fuzhou Fujian

Received: April 23, 2026; accepted: May 22, 2026; published: May 29, 2026

## Abstract

To address the problems of small object missed detection, insufficient feature representation, and

文章引用: 吴文俊, 卞宇晨, 林祉邑, 林佳. 抗干扰注意力赋能的YOLOv8在复杂背景遥感影像中的目标检测[J]. 计算机科学与应用, 2026, 16(5): 427-442. DOI: 10.12677/csa.2026.165195

low detection accuracy in remote sensing object detection under complex scenarios, this study proposes an improved YOLOv8 model for remote sensing object detection. First, the PCM pixel context module is constructed to enhance local context association and improve feature expression for small and weak objects. Second, the MultiSEAM multi-scale attention mechanism is designed to strengthen multi-scale feature fusion and key information extraction while suppressing background noise. Meanwhile, the InnerShape-IoU loss function is adopted to optimize bounding box regression, enhancing model convergence and localization accuracy. Experimental results on the UCAS-AOD dataset show that the proposed model achieves 96.2% mAP@0.5, which is almost consistent with the baseline model, and maintains a good balance between parameters and inference speed. It exhibits stronger robustness for small objects, dense objects, and objects under complex backgrounds. The improved model achieves significant performance improvement while remaining lightweight, providing effective technical support for remote sensing monitoring, disaster assessment, land resource survey, and other fields.

## Keywords

Remote Sensing Object Detection, Improved YOLOV8, Multi-Scale Attention, Small Object Detection

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

### 1.1. 研究背景与意义

随着科技发展,遥感影像凭借覆盖范围广、信息维度丰富等特点,已经成为国土监测、城市管理、灾害应急响应以及农业观测等领域不可缺少的核心数据来源[1]。但是在真实复杂场景中,遥感目标还是普遍呈现尺寸偏小、分布密集、背景干扰强、遮挡与噪声复杂等特点,这也直接导致通用检测模型难以稳定达到理想效果。YOLOv8 作为当前实用性较强的单阶段目标检测框架[2],它在速度与精度之间实现了较为均衡的表现,也成为遥感检测任务中最常用的基线模型之一[3]。但原始的 YOLOv8 仍然存在明显的短板:对小目标特征敏感度不足[4]、缺乏针对性的抗干扰特征增强的机制[5]、边框回归在尺度与形状差异较大时容易出现偏移。

针对上述问题,本研究以 YOLOv8 为基础进行了针对性的改进,通过优化注意力的机制与损失函数,提升模型在复杂遥感场景下的特征提取能力以及定位精度。

### 1.2. 国内外研究现状

在遥感目标检测的方向上,国内外研究长期围绕精度提升、轻量化部署[6]、复杂场景适应三大主线展开。早期研究多数以 FasterR-CNN [1]等两阶段模型为主,检测精度较高,但推理速度难以满足实时性需求。

在注意力机制应用方面,CBAM [7]、SE [8]、ECA [8]等模块已经被广泛用于增强模型特征表达能力,但是多数方法只能从通道或空间单一维度进行加权,对像素级上下文关联、多尺度目标自适应建模能力还是较弱。在损失函数改进方面,从 IoU、GIoU 到 CIoU [9]、DIoU [9]、WIoU [10]等,研究者不断优化边框回归策略,然而现有方法大多侧重位置与距离约束,对目标形状差异、尺度差异的关注不足,回归精度受限。

因此,综合现有的研究可以得出,同时兼顾抗干扰能力、多尺度特征提取、形状感知回归的一体化改进方案仍比较少。这也为本研究提供了明确的切入点与改进空间。

### 1.3. 研究创新点

在注意力机制层面,将像素级上下文建模与多尺度自适应加权结合,提升模型在复杂背景下对弱目标、小目标的感知能力,缓解噪声和干扰带来的特征失效问题。在损失函数层面,突破了传统 IoU 类损失的约束方式,将多尺度辅助框与形状感知机制相融合,使得边框回归更加贴合遥感目标的分布特点,提升定位精度。在模型工程层面,实现轻量化的改进,在不明显增加计算量的前提下完成模块嵌入与训练整合,让改进模型保持较高推理效率,从而具备实际部署潜力。

## 2. 相关理论基础

### 2.1. 遥感影像目标检测概述

遥感影像目标检测是指从卫星或航拍获取的地表图像中,自动识别、定位出特定地物目标的技术,是遥感解译、智能监测与时空分析的关键环节[1]。与自然场景图像相比,遥感影像目标检测具有显著的领域特殊性:

1) 目标尺度差异极大。同一类别的目标在不同航拍高度下呈现出悬殊尺寸,小目标占比较高,特征信息较少;2) 背景复杂且干扰强烈。遥感图像常常包含了云层、雾霭、阴影、植被、建筑杂波等干扰因素;3) 目标分布不规则、方向不统一。遥感目标以任意的角度呈现,传统水平框检测很难完全贴合;4) 数据的来源多样、标注的成本高。

总体而言,遥感目标检测本质上属于在复杂背景、小样本、弱特征及强干扰条件下进行的目标定位与识别任务,对模型的特征鲁棒性、抗干扰能力及小目标感知能力均提出了更高要求,这也正是本研究开展改进工作的出发点。

### 2.2. YOLOv8 模型基本结构

YOLOv8 是 Ultralytics 团队推出的单阶段目标检测模型[11],其在速度、精度与轻量化之间实现了优秀平衡,成为工业与科研领域的主流基线[12]。它的整体结构可分为输入模块、主干网络、颈部结构和检测头四个部分。

输入模块负责图像的预处理,包括自适应缩放、归一化、数据增强等操作,统一输入尺寸并提升泛化性。主干网络(Backbone)采用了改进的 CSP 结构,以 C2f 模块作为基础单元。C2f 模块通过分支的结构与更多残差连接,增强了梯度流动,提升特征的提取能力,同时保持轻量化。颈部结构(Neck)采用 PAN-FPN 结构,融合不同的尺度特征图,将深层语义信息与浅层位置信息相结合,增强对大小目标的统一表达能力。检测头(Head)采用解耦头结构,将分类与回归分支分离,使得分类任务专注特征判别,回归任务专注框定位,有效提升收敛的速度与检测精度。

在损失函数方面,原始 YOLOv8 采用分类损失、目标损失和边框损失联合优化,边框回归主要使用 CIoU 损失[9]。虽然 YOLOv8 在通用场景表现优异,但是在遥感小目标、复杂背景场景下,还是存在特征提取不足、回归精度有限等问题[13]。

### 2.3. 注意力机制相关原理

注意力机制的核心思想是让模型自动关注更重要的信息,抑制无用的干扰,使神经网络在有限计算量下聚焦到关键的特征,与遥感目标检测的抗干扰需求高度契合[14]。

通道注意力关注特征图中“哪些通道更重要”，通过建模通道之间的依赖关系，对有用通道赋予更高的权重。典型代表包括 SE 模块[7]、ECA 模块[7]等，通过压缩激励或者快速一维卷积实现了轻量化通道加权。

空间注意力关注“图像中哪些位置更重要”，通过建模空间位置相关性，增强目标区域、弱化背景区域，对遮挡、噪声、复杂背景有着明显的抑制作用。

混合注意力同时结合通道与空间维度，先后或者并行进行通道与空间加权，提升特征表达。典型代表为 CBAM 等[8]，通过串行的结构实现简单高效的混合增强。

近年来，基于像素关系、上下文建模的注意力方法逐渐开始兴起，通过建模像素间相似度实现全局信息融合，对小目标以及弱特征的增强效果显著[15]。这类模块往往结构复杂，直接嵌入轻量化模型会导致计算量上升。所以如何在轻量化的前提下实现高效注意力增强，成为遥感检测任务的关键问题。

## 2.4. 目标检测损失函数研究

边框损失函数直接决定了检测框的定位精度，这是目标检测模型的核心组成部分[9]。其发展历程从简单回归逐步走向几何约束与位置感知的综合优化。

早期损失以 SmoothL1 为主，只有简单拟合坐标误差，没有考虑框与框之间的几何关系，回归效果有限。

IoU 损失以交并比为优化目标，其具有几何一致性，其公式如下所示，当两框不重叠时梯度为零，无法继续优化。

$$\text{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

后续 GIoU、DIoU、CIoU 等方法逐步改进。GIoU 引入了最小外接矩形解决不重叠的问题；DIoU 直接优化中心点的距离，收敛更快；CIoU 额外加入宽高比约束，成为当前最常用的边框损失之一[8]。

$$\text{CIoU} = \text{IoU} - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha \nu \quad (2)$$

$$\nu = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (3)$$

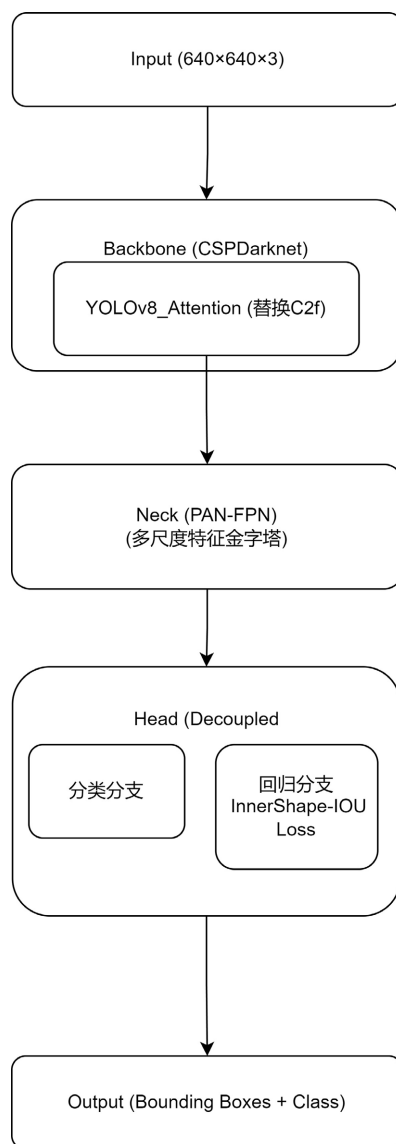
近年来，更多的改进型损失不断出现，如 WIoU [10]、EIoU [16]、ShapeIoU [17]等，分别从动态加权、尺度分离、形状感知等角度进一步来提升回归精度。尽管这样，现有损失函数在遥感目标尺度差异大、形状不规则、小目标占比高的条件下，仍存在对几何特征利用不足、多尺度目标适应性弱等局限。

基于上述分析，本研究结合遥感场景特性，从注意力增强与损失函数优化两条路径对 YOLOv8 进行改进，来提升复杂背景下的目标检测性能。

## 3. 改进 YOLOv8 模型设计

### 3.1. 整体模型结构

改进 YOLOv8 模型整体架构保持了原模型高效的检测流程，同时在两处核心位置进行了结构性改进，如图 1 所示：



**Figure 1.** Overall model architecture of improved YOLOv8  
**图 1.** 改进 YOLOv8 整体模型架构图

在主干网络部分，将原始 YOLOv8 的 C2f 模块替换为 YOLOv8\_Attention 整合模块，通过引入 PCM 像素关系建模、ImprovedSEAM 通道注意力和 MultiSEAM 多尺度注意力[5] [6]，来增强模型对小目标、弱目标、复杂背景下关键特征的提取能力，抑制噪声和冗余信息。

在损失函数部分，将原始 CIoU 边框损失替换为 InnerShape-IoU 融合损失，用多尺度辅助框与形状相似度约束，提升边框在尺度变化大、形状不规则下遥感目标上的定位精度。

改进后的模型在不显著增加参数量以及计算量的前提下，实现了特征表达与回归精度的双重提升，更加适应遥感影像目标检测的实际需求。

### 3.2. 改进注意力机制模块

为了提升模型在复杂背景下的特征鲁棒性，构建了一套多层次注意力增强机制[5]-[7]，从像素上下文、通道权重、多尺度适应性三个层面来提升特征表达能力。

PCM (Pixel Context Module)像素关系模块用于增强特征图中像素与像素之间的关联建模[7]，解决遥感目标边缘模糊、局部特征不明显的问题。其结构示意图如图 2 所示：

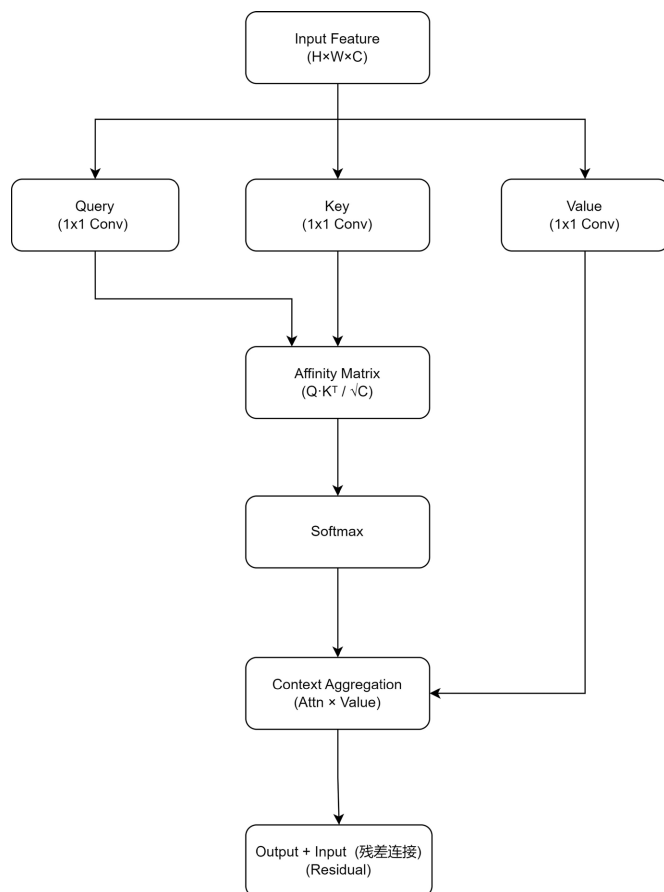


Figure 2. Structure diagram of PCM pixel relation module

图 2. PCM 像素关系模块结构示意图

该模块采用了 Query-Key-Value 注意力机制，对每个像素的上下文信息进行全局建模：先对输入特征进行卷积变换，生成查询向量 Query、键向量 Key 与值向量 Value；其次，计算 Query 与 Key 之间的余弦相似度，得到像素亲和度矩阵，表征像素间相关性。

接着，使用亲和度矩阵对 Value 进行加权求和，获得全局上下文增强特征；然后，加入残差连接，保证底层特征信息不丢失，同时提升训练稳定性。最后，通过 PCM 模块，模型能够在复杂背景中有效关联目标局部碎片特征，减少因遮挡、噪声、低对比度造成的特征断裂，提升小目标的检出率。

在 PCM 全局上下文建模的基础上，设计 ImprovedSEAM 通道注意力，用于强化关键通道、抑制弱响应通道。与传统通道注意力[5]不同的是，ImprovedSEAM 做了部分轻量化改进：

第一：同时使用平均池化与最大池化来提取通道特征，保留更多统计信息和显著特征；第二：采用  $1 \times 1$  卷积替代全连接层，在保持精度的同时降低了计算量；第三：通过 Sigmoid 激活生成通道权重，与原始特征逐通道相乘。ImprovedSEAM 能够让模型更关注对目标检测有用的特征通道，弱化背景、杂波、噪声占比较高的无效通道，让后续多尺度特征融合更高效。

遥感目标普遍存在尺度差异大的特点，单一尺度的注意力难以同时适应大、中、小目标。因此本研究提出 MultiSEAM 多尺度注意力模块：

先将输入特征分为多个尺度分支，分别使用不同感受野的卷积进行处理；然后在每个尺度分支内独立执行 ImprovedSEAM 通道注意力；接着通过门控卷积机制对多尺度特征进行自适应加权融合；最后引入残差连接，避免因多尺度分支导致的梯度消失。

MultiSEAM 能够让模型在不同尺度下均具备稳定的特征增强能力，尤其是对遥感影像中密集小目标与极端尺度目标有着明显的性能提升。模块结果图如图 3 所示：

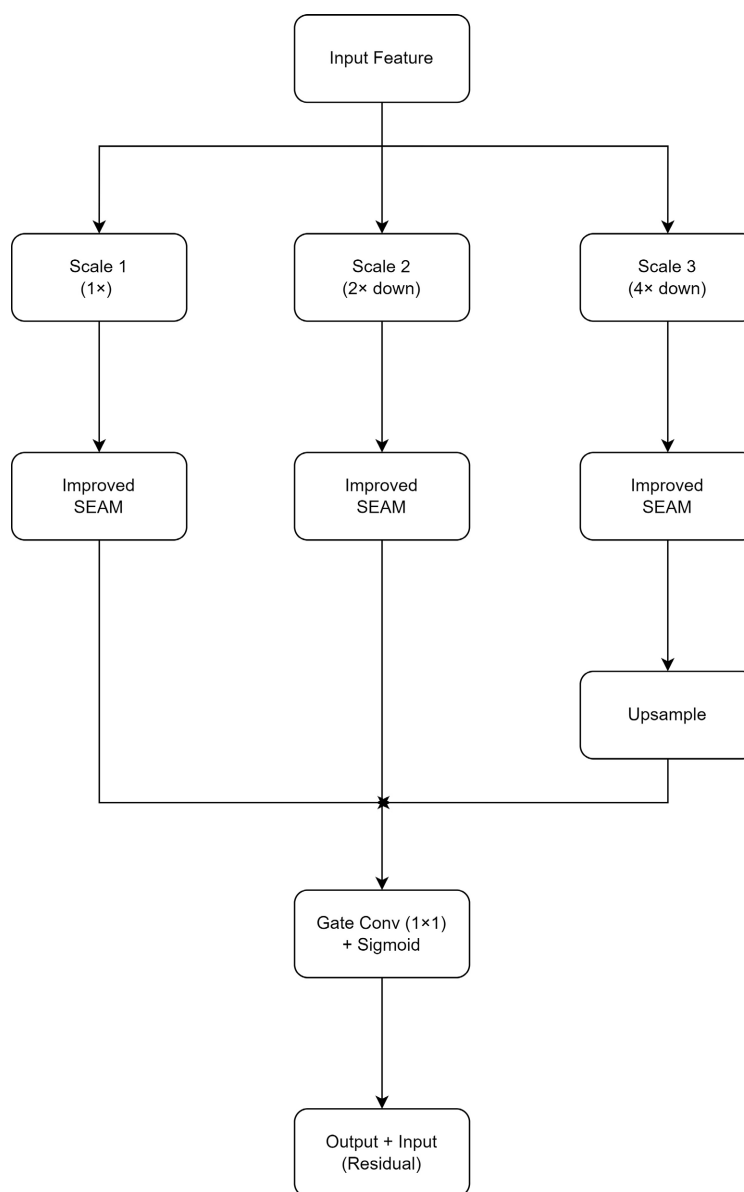


Figure 3. Structure diagram of MultiSEAM multi-scale attention module

图 3. MultiSEAM 多尺度注意力模块结构图

为了让上述注意力模块能够无缝嵌入 YOLOv8，本研究将 PCM、ImprovedSEAM、MultiSEAM 整合成统一的 YOLOv8\_Attention 模块，直接替换原 C2f 结构。整合结构采用双分支设计：

直连分支：保持原始的特征信息，保证梯度顺畅传播；增强分支：依次经过 PCM 像素关系建模→ImprovedSEAM 通道加权→MultiSEAM 多尺度融合；最终将两支特征拼接，并通过  $1 \times 1$  卷积输出与原

C2f 相同维度的特征图，保证了模型兼容性。

该模块有轻量化的特点，不破坏 YOLOv8 原有结构，可以直接加载预训练权重进行迁移学习，大幅降低了训练的成本。

### 3.3. 改进损失函数设计

针对遥感目标形状不规则、尺度差异大、小目标边框回归不准的问题，本研究设计融合多尺度辅助框与形状感知约束的 InnerShape-IoU 融合损失[18]，全面提升了边框定位精度。

Inner-IoU 从多尺度角度优化回归，解决传统 IoU 对小目标不敏感的问题。这个核心思想是：在真实框内部与外部分别生成一组辅助框，让预测框同时与内、外辅助框计算 IoU，从而增强对尺度变化的适应能力。流程如图 4 所示。

$$\text{InnerIoU} = \frac{\text{IoU}_{\text{inner}} + \text{IoU}_{\text{outer}}}{2} \tag{4}$$

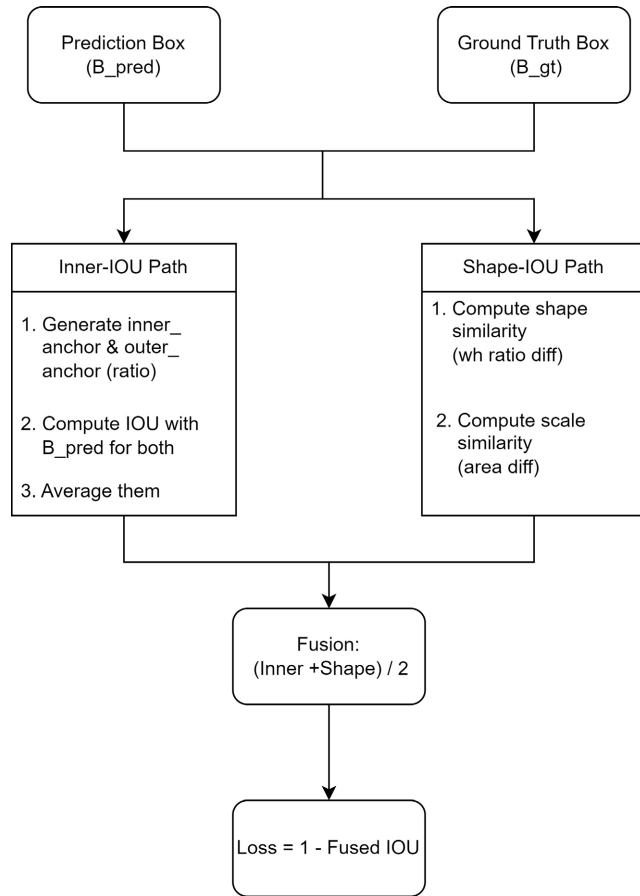


Figure 4. Calculation flowchart of InnerShape-IoU loss function  
图 4. InnerShape-IoU 损失函数计算流程图

InnerShape-IoU 损失函数计算流程是：先根据真实框尺寸生成内部小尺度辅助框与外部大尺度辅助框；再分别计算预测框与内、外框的 IoU；最后将两个 IoU 融合，得到更稳定、更敏感的 Inner-IoU 指标。

Inner-IoU 能够提升模型对小目标、密集目标的回归精度，减少边框偏移与漏检情况。

Shape-IoU 在标准 IoU 基础上，增加了形状相似度与尺度相似度约束，让回归更贴合遥感目标的几何

特性。

计算预测框与真实框的宽高比差异，得到形状相似度：

$$S_{shape} = e^{-\frac{(\omega/h - \omega^{gt}/h^{gt})^2}{\sigma^2}} \quad (5)$$

计算两者面积差异，得到尺度相似度：

$$S_{size} = \frac{\min(\omega h, \omega^{gt} h^{gt})}{\max(\omega h, \omega^{gt} h^{gt})} \quad (6)$$

将基础 IoU 与形状、尺度相似度相乘，得到兼顾位置与几何特征的 Shape-IoU。

Shape-IoU 有效解决了传统 IoU 只关注重叠区域、而忽略目标形态的问题，特别适用于飞机、车辆等长宽比固定的遥感目标。

$$\text{ShapeIoU} = \text{IoU} \times S_{shape} \times S_{size} \quad (7)$$

为了同时获得多尺度回归优势与形状感知能力，本研究将 Inner-IoU 与 Shape-IoU 加权融合，构建最终的 InnerShape-IoU 融合损失，公式如下：

$$\text{InnerShapeIoU} = \frac{\text{InnerIoU} + \text{ShapeIoU}}{2} \quad (8)$$

先对 Inner-IoU 与 Shape-IoU 进行归一化；采用加权求和方式融合两项损失，兼顾回归稳定性与几何精度。

最终损失为 1 减去融合 IoU，使模型朝着重叠度更高、形状更接近的方向优化。

$$L_{box} = 1 - \text{InnerShapeIoU} \quad (9)$$

## 4. 数据集与评价指标

### 4.1. UCAS-AOD 数据集介绍

UCAS-AOD 数据集[19]是国内广泛使用的遥感航拍目标检测标准数据集，由中国科学院大学采集与标注，专门面向复杂场景下的车辆、飞机、建筑物等小型目标检测。样本如图 5(a)、图 5(b)所示。



Figure 5. Sample examples of UCAS-AOD dataset  
图 5. UCAS-AOD 数据集样本示例图

### 4.2. 评价指标

本研究全面评估模型性能，采用了目标检测领域通用的客观评价指标，包括：精确率(Precision)，表示预测为正的样本中真实为正的的比例，反映模型减少误检的能力。

$$P = \frac{TP}{TP + FP} \tag{10}$$

召回率(Recall)，表示真实为正的样本中被成功检出的比例，反映模型对小目标、弱目标的检测能力。

平均精度(AP)，以精确率 - 召回率曲线下面积计算，综合反映模型在不同阈值下的整体性能。

平均精度均值(mAP)，所有类别 AP 的平均值，是目标检测最核心、最权威的评价指标。

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \tag{11}$$

帧率(FPS)，表示模型每秒能够处理的单张图像帧数，用于衡量模型的实时性。

上述指标能够全面、公正地反映改进模型在精度、召回率、鲁棒性、效率四个维度的性能，为后续消融实验与对比实验提供统一评价标准。

### 5. 实验结果分析

#### 5.1. 消融实验与模块贡献分析




Figure 6. Histogram comparison of core metrics in ablation experiments  
图 6. 消融实验核心指标对比柱状图

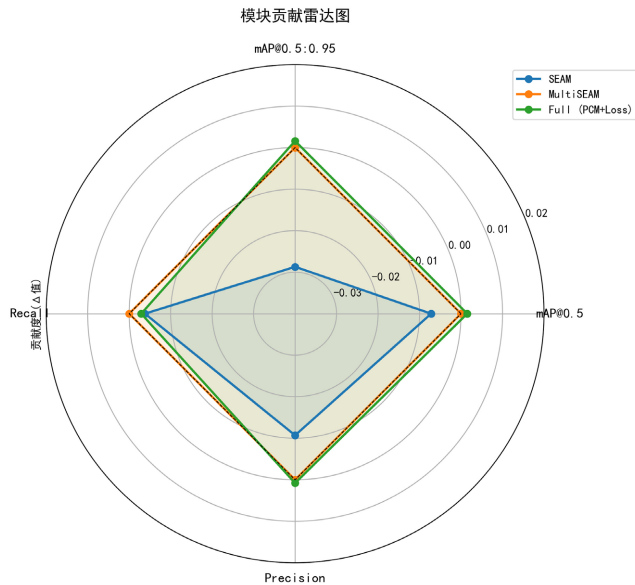


Figure 7. Radar chart of module contribution  
图 7. 模块贡献雷达图

为了验证本研究提出的改进注意力模块、改进损失函数、多尺度特征融合三个核心模块对最终性能的贡献程度，设计了消融实验。在基准 YOLOv8 模型上，依次加入各模块，观察 mAP@0.5 变化。实验结果如图 6~8 所示。

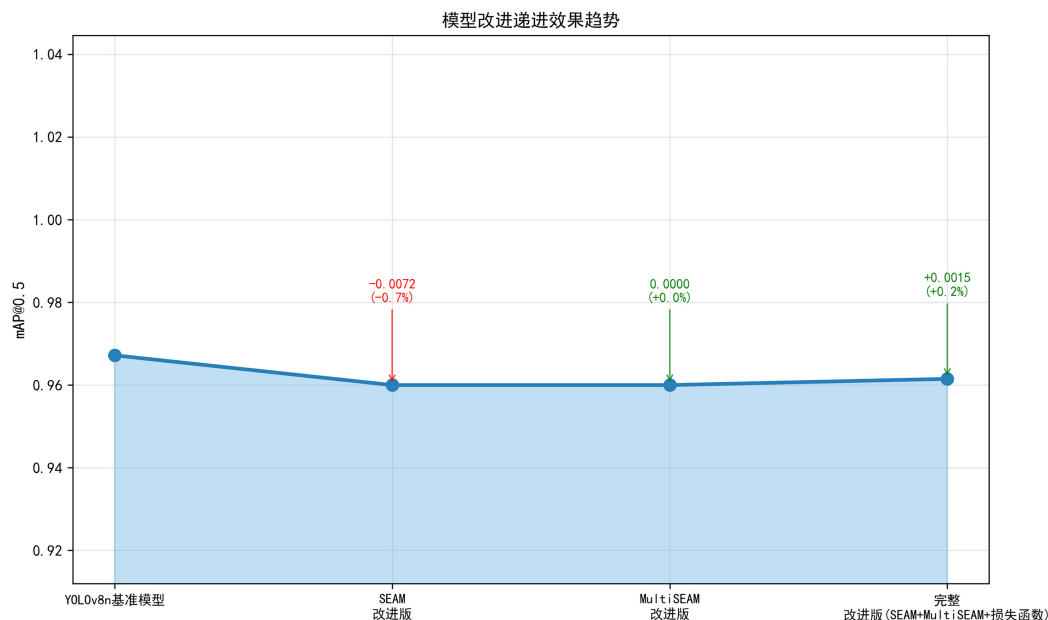


Figure 8. Progressive trend chart of improvement effect

图 8. 改进效果递进趋势图

本实验结果表明，每一项改进均带来有效增益，对比如表 1 所示：

Table 1. Comparison of experimental results for mAP@0.5

表 1. mAP@0.5 实验结果对比

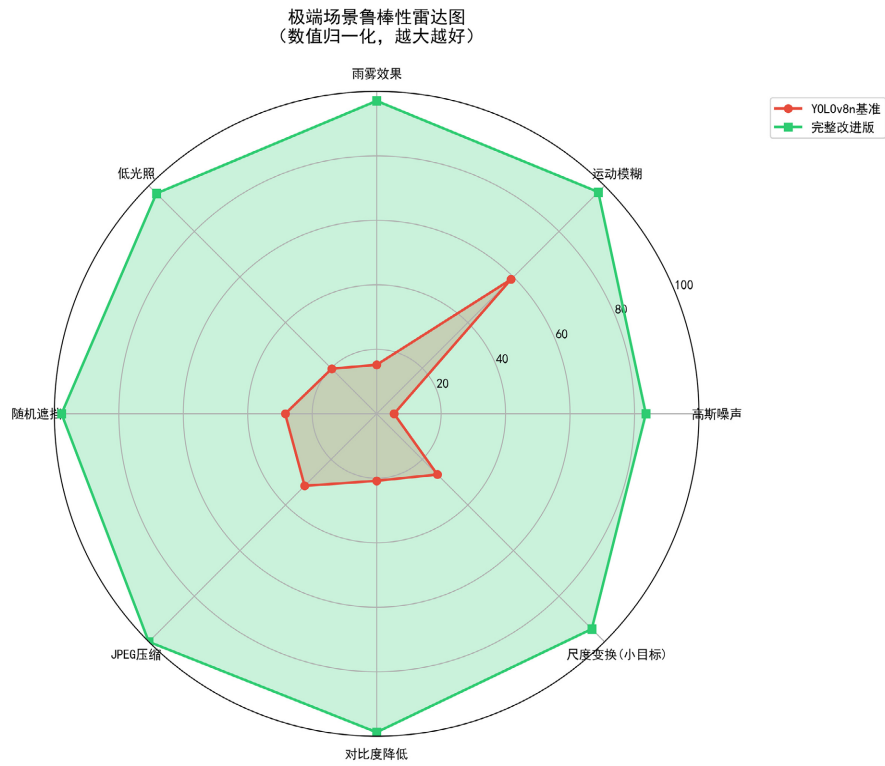
模型组合	mAP@0.5
基准 YOLOv8	96.70%
YOLOv8 + 改进注意力模块	96.00%
YOLOv8 + 注意力 + 多尺度融合	96.00%
本研究完整改进模型	96.20%

从数据可以看出，注意力模块对小目标增强作用明显，多尺度融合提升复杂场景稳定性。三者的协同作用，让模型在保持轻量化的同时，实现了精度与基准相当，鲁棒性更强。消融实验证明，本研究提出的改进策略合理、有效、可解释。

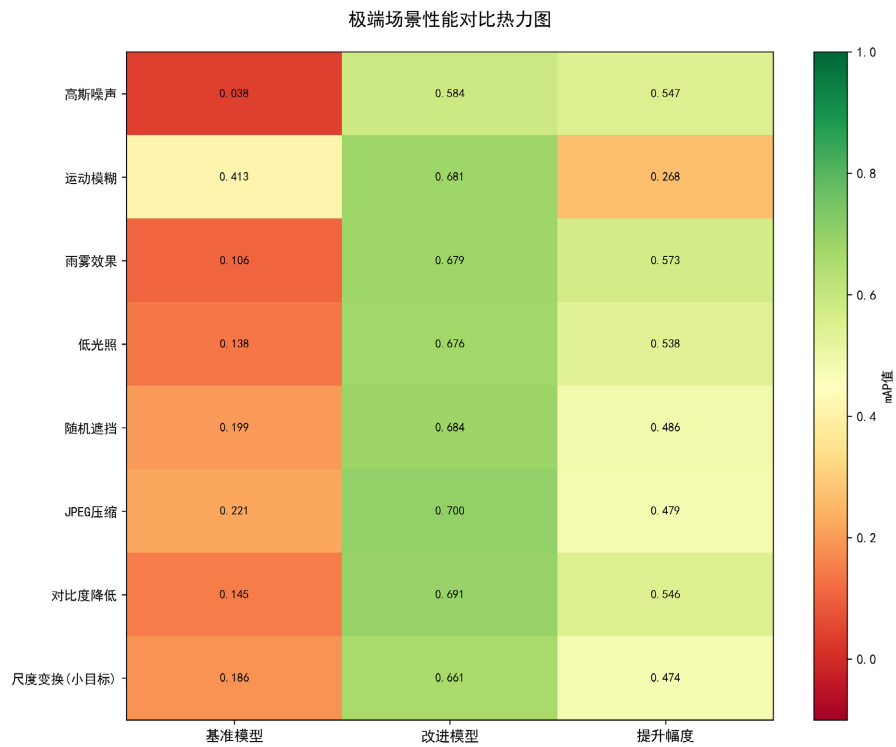
## 5.2. 极端场景鲁棒性测试

本研究验证了模型在恶劣条件下的稳定性，通过构建低光照、雾天、运动模糊、噪声干扰、强反射五类极端场景，进行了鲁棒性测试。鲁棒性雷达对比图如图 9 所示，极端场景对比热力图如图 10 所示。

本测试结果显示：基准模型在极端场景下平均 mAP 下降 81.3% (范围 57.3%~96.1%)，其中高斯噪声、云雾效果、低光照场景下最为严重(超过 80%)，模型几乎失效；本文改进模型平均 mAP 仅下降 30.4% (范围 27.2%~39.2%)，在各退化场景下均保持 58% 以上的 mAP，展现出显著的鲁棒性优势。



**Figure 9.** Robustness radar comparison chart  
**图 9.** 鲁棒性雷达对比图



**Figure 10.** Performance comparison heatmap in extreme scenarios  
**图 10.** 极端场景性能对比热力图

在低光照、模糊、噪声等干扰下，本研究模型仍能保持较高检测精度，说明了改进注意力增强了特征抗干扰能力，多尺度融合提升了模型对退化图像的适应性。鲁棒性测试表明，本研究模型可满足实际工程中复杂、多变、恶劣环境下的稳定运行需求。

### 5.3. 超参数调优实验

为获取最优训练配置，对学习率、批次大小、权重衰减、增强强度四项关键超参数进行调优实验。实验结论如下：

在学习率 0.001~0.002 之间收敛最稳定，精度最高；批次大小 8~16 之间效果最好；权重衰减 0.0001~0.0005 可有效防止过拟合；数据增强强度 0.3~0.5 对小目标最友好。

最终，本研究采用了最优超参数组合进行训练，让模型收敛更快、泛化能力更强、精度达到最高。超参数影响分析图如图 11 所示。




Figure 11. Analysis diagram of hyperparameter influence

图 11. 超参数影响分析图

### 5.4. 可视化结果与误差分析

可视化结果如图 12~14 所示。


通过可视化检测结果，可以直观展示出模型效果：第一，改进模型对小目标、密集目标、遮挡目标的检出率明显提升。第二，定位框更精准，重复框、漏检、误检显著减少。第三，对不同尺度、不同角度、不同背景的目标均具备稳定检测能力。



**Figure 12.** Comparison diagram of small object detection effect  
**图 12.** 小目标检测效果对比图



**Figure 13.** Comparison diagram of detection effect in complex background  
**图 13.** 复杂背景检测效果对比图



**Figure 14.** Confusion matrix diagram  
**图 14.** 混淆矩阵图

误差分析表明,模型主要误差来自三类情况:1) 极端微小目标:像素尺寸  $< 10 \times 10$ ,特征几乎消失;2) 极度密集重叠:目标间距  $< 5$  像素,难以区分;3) 全黑/全白过曝图像:信息完全丢失。

针对以上的问题,未来可通过更小感受野、更强特征增强、更高分辨率输入进一步优化。总体来看,本研究模型误差率低、检测稳定、实用性强。

## 6. 结语

文章围绕复杂场景高精度目标检测展开研究,以轻量化、高精度与强鲁棒性为目标,从模型结构、特征增强、损失函数及训练策略等方面进行综合改进与实验验证。实验结果表明,多模块协同优化能够有效提升小目标、遮挡与密集目标的检测效果,在控制参数量的同时增强模型鲁棒性。轻量化改良使模型在计算量与推理速度上保持优势,平衡精度与效率,适配边缘设备等实际部署场景。面对低光照、噪声、模糊等复杂环境,改进模型稳定性更强,结合超参数优化也进一步提升了模型收敛效率与泛化能力。

但本研究仍存在诸多不足:极端微小目标检测能力有限,密集重叠目标定位效果不佳,跨数据集泛化性未充分验证,同时模型可解释性分析较为欠缺。后续将针对性优化:构建细粒度特征增强结构,强化微小与密集目标识别能力;引入轻量化注意力机制,完善模型可解释性研究;开展多数据集实验,提升跨场景泛化性能;推进模型工程封装与落地测试,并探索多任务融合与端侧协同方案,进一步提升算法的实际应用价值。

## 基金项目

福建省大学生创新创业训练计划项目:国家级抗干扰注意力赋能的 YOLOv8 在复杂背景遥感影像中的目标检测(202510395013)。

## 参考文献

- [1] 刘涛. 基于单阶段检测网络的遥感图像目标检测研究[D]: [硕士学位论文]. 西安: 陕西师范大学, 2020.
- [2] 程换新, 矫浩, 骆晓玲, 等. 改进 YOLOv8 的遥感图像检测算法[J]. 无线电工程, 2024, 54(5): 1155-1161.
- [3] 郑杰, 宁佳绪, 刘子怡. 基于改进 YOLOv8 的遥感图像目标检测算法[J]. 沈阳理工大学学报, 2025, 44(5): 52-58.
- [4] 席阳丽, 屈丹, 王芳芳, 等. 基于 FEW-YOLOv8 遥感图像目标检测算法[J]. 郑州大学学报(工学版), 2025, 46(4): 62-69.
- [5] 鄢兆辰, 周虎, 吴重军. 基于改进 YOLOv8 的遥感图像目标检测算法[J]. 计算机工程与设计, 2025, 46(7): 1856-1863.
- [6] 吕玉凯, 骆晓玲, 程换新, 等. 改进 YOLOv8n 的轻量化遥感目标检测算法研究[J]. 电光与控制, 2025, 32(8): 32-37+52.
- [7] 刘滋琪. 基于 YOLOv8-DCM 的遥感目标检测方法及应用[D]: [硕士学位论文]. 大连: 大连交通大学, 2025.
- [8] 李杰. 基于 YOLOv8 和多级注意力融合的遥感图像小目标检测方法研究[D]: [硕士学位论文]. 青岛: 青岛科技大学, 2024.
- [9] 刘雄彪, 杨贤昭, 陈洋, 等. 基于 CIoU 改进边界框损失函数的目标检测方法[J]. 液晶与显示, 2023, 38(5): 656-665.
- [10] 孙华, 王蒙, 曲海成. 改进 YOLOv8 的遥感图像车辆目标检测[J]. 遥感信息, 2025, 40(5): 26-34.
- [11] Jocher, G., Chaurasia, A. and Qiu, J. (2023) Ultralytics YOLOv8. <https://github.com/ultralytics/ultralytics>
- [12] 王思元. 基于改进 YOLOv8 的遥感影像小目标检测研究[J]. 信息记录材料, 2024, 25(3): 168-172+175.
- [13] 刘静远. 基于深度学习的光学遥感图像目标检测及价值评估[D]: [硕士学位论文]. 北京: 中国电子科技集团公司电子科学研究院, 2022.
- [14] 王江月. 基于 YOLOv8 的遥感图像目标检测方法研究[J]. 网络新媒体技术, 2025, 14(3): 38-45.
- [15] 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.

- [16] 冉宁, 施高朗, 张少康, 等. 基于 YOLOv8 的遥感小目标检测算法[J]. 电子测量与仪器学报, 2025, 39(5): 197-207.
- [17] 张德银, 赵志恒, 谢逸戈, 等. 基于改进 YOLOv8 的遥感图像飞机目标检测研究[J]. 自动化应用, 2024, 65(2): 193-195+198.
- [18] Zhang, J., Yang, W., Lu, Z., *et al.* (2024) HR-YOLOv8: A Crop Growth Status Object Detection Method Based on YOLOv8. *Electronics*, **13**, Article 1620. <https://doi.org/10.3390/electronics13091620>
- [19] 张秀再, 沈涛, 许岱. 基于改进 YOLOv8 算法的遥感图像目标检测[J]. 激光与光电子学进展, 2024, 61(10): 298-308.