

DOI: 10.20189/j.cnki.CN/61-1527/E.202501007

基于双层注意力机制的遥感小目标检测算法

陈谢发, 李 敏, 赵晶钰, 吕奕龙, 何玉杰
(火箭军工程大学, 陕西 西安 710025)

摘 要: 针对遥感图像目标检测任务中小尺寸目标特征信息弱的问题, 提出了一种基于空间及通道双层注意力机制的遥感图像小目标检测算法。该算法基于 YOLOv8n 网络架构, 融合了空间与通道双层注意力的特征信息, 在放大跨维度间交互作用的同时, 使检测更多关注于特征图重点区域信息, 从而提升对小目标的检测能力; 同时, 改进回归损失函数, 结合焦点、权重交并比 2 种损失函数, 解决了训练过程中难易正确分类样本间不平衡的问题, 并对目标框之间的相似度进行更准确的度量, 进一步提高了算法对目标位置和大小检测精度及稳定性。在工程车遥感数据集上, 所提算法较 YOLOv8n 算法的 mAP@0.5 提高了 3.6%, mAP@0.5 : 0.95 提高了 2.9%; 在 NWPU VHR-10 数据集上, 所提算法较 YOLOv8n 算法的 mAP@0.5 提高了 1.6%, 但 mAP@0.5 : 0.95 略有下降。在 2 个数据集上的消融实验结果表明, 所提算法能够准确识别图像中的小尺寸目标, 对比原模型的目标检测置信度有显著上升, 证明了改进措施的有效性。

关键词: 遥感图像; 小目标检测; 全局注意力; 损失函数; YOLOv8n

中图分类号: TP751.1

文献标志码: A

文章编号: 2097-2741(2025)01-060-07

Remote Sensing Small Object Detection Algorithm Based on Dual-layer Attention Mechanism

CHEN Xiefa, LI Min, ZHAO Jingyu, LYU Yilong, HE Yujie
(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: To address the problem of weak feature information of small objects in remote sensing image object detection tasks, a small-object detection algorithm for remote sensing images was proposed based on the dual-layer attention mechanism of channel and spatial features. The algorithm was based on YOLOv8n and integrated dual-layer feature information from both the channel and space. While amplifying cross-dimensional interactions, it focused on detecting the key area information of the feature map. Therefore, the ability to detect small objects was enhanced. Meanwhile, by improving the regression loss function and combining the focus loss function and weight intersection ratio loss function, the problem of imbalanced samples being difficult to classify correctly during the training process was solved, and the similarity between object boxes was more accurately measured. Thereby, the accuracy and stability of the algorithm's de-

收稿日期: 2024-07-17

第一作者: 陈谢发 (1995—), 男, 硕士研究生, 主要从事目标检测研究。E-mail: 1435013720@qq.com

引用格式: 陈谢发, 李敏, 赵晶钰, 等. 基于双层注意力机制的遥感小目标检测算法[J]. 火箭军工程大学学报, 2025, 39 (1): 60-66. CHEN Xiefa, LI Min, ZHAO Jingyu, et al. Remote sensing small object detection algorithm based on dual-layer attention mechanism [J]. Journal of Rocket Force University of Engineering, 2025, 39 (1): 60-66.

tection of object position and size were further improved. On the engineering vehicle remote sensing data set, the mAP@0.5 and the mAP@0.5 : 0.95 of the proposed algorithm was 3.6% and 2.9% higher than that of YOLOv8n respectively. On the NWPU VHR-10 data set, the mAP@0.5 of the proposed algorithm was 1.6% higher than that of YOLOv8n, however, the mAP@0.5 : 0.95 was slightly lower. The results of ablation experiments on two data sets showed that the proposed algorithm can accurately identify small objects in images, and the confidence level of object detection significantly increases compared to that of the original model, proving the effectiveness of the improvement measures.

KEYWORDS: remote sensing image; small object detection; global attention; loss function; YOLOv8n

随着遥感技术和深度学习技术的发展, 基于深度学习的遥感图像目标检测被广泛应用于军事任务中, 为指挥决策、精确打击提供重要的信息支撑, 军事需求的增加对目标检测性能提出了更高的要求。但在遥感图像目标检测^[1]中, 由于航天器成像距离远, 存在目标尺寸小、检测背景复杂等问题, 识别精度的不足也会造成漏检误检等问题发生。随着遥感目标检测技术的进步, 检测精度在逐渐提高, 但仍面临诸多挑战, 如遥感目标多样化、图像背景复杂化和目标特征信息弱等。

目前, 遥感目标检测^[2]算法包括更快速的基于区域的卷积神经网络^[3] (Faster Region-based Convolutional Neural Network, Faster R-CNN)、YOLO^[4] (You Only Look Once, YOLO) 系列算法、单发多框检测器^[5] (Single Shot Multi-box Detection, SSD) 等。其中, Faster R-CNN通过优化分类网络来提高算法对目标的检测能力; YOLO系列算法通过改进网络结构、优化损失函数、对数据进行增强等途径, 提高了算法对目标的检测能力; SSD通过预设的锚框提高了算法的检测性能。

近年来, 在目标检测优化方面, 为解决图像背景复杂化问题, 注意力机制的引入成为了研究热点。Lim 等^[6]提出一种融合目标上下文信息的注意力机制, 使网络聚焦于需要重点关注部分, 从而降低背景信息的干扰。此外, 还有直接增强目标特征的优化方法来解决目标多样性问题, 主要有以下3类: 一是设计生成对抗网络 (Generative Adversarial Network, GAN)^[7], 如 Bai 等^[8]提出的 SOD-MTGAN (Small Object Detection via Multi-task Generative Adversarial Network), Rabbi 等^[9]提出的增强型超分辨率生成对抗网络等, 都是对 GAN 网络的改进; 二是对训练用数据

集进行数据增强, 如 Kisantal 等^[10]提出将目标复制增多来提高网络对目标的训练量, Zoph 等^[11]提出强化学习的方法, 先将质量好的数据进行筛选再训练, 有效提高了检测性能; 三是融合多尺度特征图来提升算法的检测精度, 如 Zeng 等^[12]提出的空洞空间金字塔池化平衡特征金字塔网络, 有效融合了不同尺度特征信息, 提升了算法对目标的检测精度。以上方法都仅对遥感图像的目标多样性和背景复杂性等问题进行了深入探讨, 但还存在遥感目标特征信息弱、对小尺寸目标检测精度低等问题。

针对上述存在的问题, 本文先后在通道和空间2个层面形成注意力, 从而增强目标特征信息; 通过优化损失函数, 提高算法对难以检测样本的识别能力。与现有算法相比, 本文不仅更加关注于难测样本, 还进一步增强了难以检测样本的目标特征, 对遥感小目标检测任务更加具有优势。实验结果表明, 本文算法能够准确识别图像中的小尺寸目标, 对比原模型的目标检测置信度有显著上升, 从而验证了本文算法的有效性。

1 YOLOv8n-GAM-Focal_WIoU 算法

在当前目标检测算法中, YOLOv8n 作为一阶段检测算法, 无需预设锚框, 在检测速度和检测精度方面具有较好的平衡性和优势, 故本文选其作为基线算法。但该算法在提取特征的过程中, 由于卷积和池化操作, 会导致原始图像的很多信息丢失。对于遥感小目标而言, 这些操作会进一步减少其特征信息, 降低算法对目标的检测精度。同时, 由于遥感目标尺寸小、特征信息弱, 会导致较深的特征图可能无法提供足够的精度来对目标进行准确定位。针对上述问题, 本文提出了一

种基于注意力机制特征增强的 YOLOv8n-GAM-Focal_WIoU 算法, 通过引入双层注意力机制^[13]来增强目标特征信息, 同时优化损失函数, 使模型更加关注于对难检测样本的学习。

1.1 模型网络结构

本文改进后的模型总体网络结构如图 1 所示。其中: Conv 为卷积; Upsample 为上采样; Concat 为特征图拼接; head 为检测头; C2f 为双层卷积; SPPF (Spatial Pyramid Pooling-Fast) 为快速空间金字塔池化。




图 1 改进模型总体网络结构

Fig. 1 Overall network diagram of improved model

1.2 通道-空间双层注意力机制引入

双层注意力机制是一种用于减少信息损失并放大大局维度互动特征的机制, 其首先关注通道注意力, 然后关注空间注意力。这种处理顺序使模型能够首先关注到最重要的通道信息, 再根据这些信息整合空间信息。本文在基线算法中颈部网络的第二个上下文感知跨层融合模块后加入了通道和空间双层注意力, 通过全局信息对整个输入图片上的特征进行建模, 使网络能够更好地了解图像中的全局结构与关系。同时, 通过一种全局的方式吸引和融合通道与空间的特征信息, 提高算法对不同尺度和分辨率目标的感知能力。

双层注意力总体结构模型如图 2 所示, 包括通道注意力子模块和空间注意力子模块。




图 2 双层注意力结构模型

Fig. 2 Dual-layer attention structure model

运算过程如下:

$$F_2 = M_c(F_1) \otimes F_1$$

$$F_3 = M_s(F_2) \otimes F_2$$

式中: F_1 为输入特征; F_2 为通道注意力子模块输出特征; F_3 为空间注意力子模块输出特征; M_c 为通道注意力; M_s 为空间注意力; $\otimes$ 表示克罗内克积。2 个模块均不包含池化操作, 所以输出张量的形状等于输入张量的形状。

在通道注意力子模块中, 使用 3D 排列来跨 3 个维度 (通道、空间宽度和高度) 保留信息, 并通过一个双层的多层感知机 (Multilayer Perceptron, MLP) 来增强跨维度的通道-空间依赖性, 模型结构如图 3 所示。图中, C 为图片通道数, H 为图片高度, W 为图片宽度。多层感知机能够建模通道之间的非线性关系, 因此, 输出参数更多体现通道之间的关系。




图 3 通道注意力子模块

Fig. 3 Channel attention sub-module

经过多层感知机运算后, 建立特征图多个通道之间的非线性关系。运算过程为

$$h_1 = f(w_{1,1} \cdot x_1 + w_{2,1} \cdot x_2 + w_{3,1} \cdot x_3 + b_0)$$

$$h_2 = f(w_{1,2} \cdot x_1 + w_{2,2} \cdot x_2 + w_{3,2} \cdot x_3 + b_1)$$

$$y = v_1 \cdot h_1 + v_2 \cdot h_2$$

式中: x 为 F_1 经过维度转换的输入特征; y 为多层感知机的输出特征; w 为权重; b 为偏置; $f()$ 为隐藏层的激活函数; v 为激活函数的参数。

在空间注意力子模块中, 通过卷积和 sigmoid 激活函数实现了空间信息融合, 模型结构如图 4 所示。其中: r 为所有通道数和通道注意力关注到的通道数间的比值。




图 4 空间注意力子模块

Fig. 4 Spatial attention sub-module

双层注意力机制采用 2 个卷积层进行空间信息融合, 同时去除了可能导致信息减少的最大池化操作, 这有助于模型更好地关注空间信息。使用 2 个大小为 7×7 的卷积, 对图像中像素点的非线性

关系进行建模。因此, 多层感知机输出参数更多体现像素空间之间的关系。

1.3 损失函数优化

本文结合焦点损失函数 (Focal Loss)^[14] 和权重交并比损失函数 (WIoU Loss)^[15] 提出了 Focal_WIoU 损失函数, 用于替换基线算法中的完整交并比 (Complete Intersection over Union, CIoU) 损失函数。Focal Loss 通过聚焦因子来调整难易样本的权重, 使模型更加关注难分样本的学习, 用于解决难易样本不平衡问题; WIoU Loss 可对目标框之间的相似度进行更准确的度量, 进一步提高模型对目标位置和大小的检测精度。YOLOv8n 算法的损失函数由分类损失 (交叉熵损失函数) 和回归损失 (完整交并比损失函数与分布式焦点损失函数) 的 3 个损失函数加权组合而成。为解决原算法中完整交并比损失函数未考虑难易样本的平衡, 导致对小目标检测不稳定的问题, 本文提出了用 Focal_WIoU 损失函数替换原算法中的 CIoU 损失函数, 使模型在训练时更加关注那些难以分类但对检测性能影响较大的样本, 从而提高模型的检测精度和鲁棒性。

Focal_WIoU 损失函数的计算公式为

$$F_{\text{Focal_WIoU}} = F_{\text{Focal}} + F_{\text{WIoU}}$$

式中: $F_{\text{Focal_WIoU}}$ 为 Focal_WIoU 损失函数; F_{Focal} 为焦点损失函数; F_{WIoU} 为权重交并比损失函数。

焦点损失函数计算公式为

$$F_{\text{Focal}} = -y_1(1-p)^\gamma \log(p) - (1-y_1)p^\gamma \log(1-p)$$

式中: p 为样本真实类别的预测概率; γ 为调节权重因子的超参; y_1 根据样本是否是真实类别, 取值为 0 或 1, $y_1 = 1$ 表示样本是真实类别, $y_1 = 0$ 表示样本不是真实类别。Focal 损失函数中引入系数因子 $(1-p)^\gamma$, 实现了根据预测结果和真实标签之间的差异程度来调整样本对损失的贡献程度。当差异越小时, 表示预测越准确, 此时应降低损失权重; 反之增加损失权重, γ 越大, 调节力度相应也越大。当没有该项因子时, Focal 损失函数是标准的交叉熵形式。

WIoU 在计算时考虑了不同区域的重要性, 并给予他们不同的权重。在 WIoU 中, 预测框与真实框之间的交集和并集都会被赋予不同的权重。计算公式为

$$F_{\text{WIoU}} = \frac{w_1 P_T}{w_1 P_T + P_F + N_F - w_2 P_T}$$

式中: P_T 、 P_F 、 N_F 分别为真正例、假正例和假反例的数量; w_1 和 w_2 为权重参数。通过调整权重参数的值, 有助于模型更好地关注对检测性能影响较大的区域, 如目标边界等。

2 实验与分析

2.1 实验数据及设置

2.1.1 实验数据集

使用工程车遥感图像数据集和 NWPU VHR-10 数据集对所提算法进行对比验证。在工程车遥感图像数据集中, 共包含 415 张遥感图像, 小目标尺寸约为图片尺寸的 1/10, 将其中的 375 张图像作为训练集, 其余均为测试集; NWPU VHR-10 数据集由西北工业大学于 2014 年发布, 包含飞机、船、交通工具等 10 种类型的遥感地物目标, 共计 650 张图像。其中, 交通工具为尺寸小于图片尺寸 1/10 的小目标, 将其按照 8:2 划分为训练集和测试集。

2.1.2 实验环境及评价指标

软件环境为 Ubuntu 18.04 操作系统, 采用 Torch 2.3.0 深度学习框架, Python 版本为 3.8, 开发工具为 Pycharm+Anaconda。平台硬件配置如下: CPU 处理器为 Intel Xeon (R) Silver 4210R, 64 GB 内存, GPU 为 NVIDIA TITAN RTX, 12 GB 显存。

性能评价指标有 mAP@0.5、mAP@0.5:0.95、参数量和每秒十亿次的浮点运算数 (Giga Floating-point Operations Perseconds, GFLOPs)。其中: mAP@0.5 表示交并比阈值为 0.5 时待检测目标的平均检测精度, mAP@0.5:0.95 表示交并比阈值为 0.5~0.95 时待检测目标的平均检测精度, 其数值越高, 表明检测精度越高; 参数量和每秒十亿次的浮点运算数用来衡量算法复杂度, 其数值越高, 表明该算法越复杂。

2.2 对比实验

为验证本文所提算法, 在工程车遥感数据集和 NWPU VHR-10 数据集上分别对不同的检测算法进行对比实验, 结果如表 1 所示。其中, 粗体数字表示每列的最优值。

由表 1 可知, 在工程车遥感数据集上, 本文算法较 YOLOv8n 算法的 mAP@0.5 提高了 3.6%, mAP@0.5:0.95 提高了 2.9%, 检测精度均优于其

他算法；在 NWPU VHR-10 数据集上，本文算法较 YOLOv8n 算法的 mAP@0.5 提高了 1.6%，但 mAP@0.5 : 0.95 降低了 1.4%。这可能是由于该数据集集中既包含交通工具、飞机和船舶等小尺寸目标，还包含桥和港口等大尺寸目标，本文算法对某类别目标的检测精度低，导致对所有类别的平均检测精度下降。

表 1 算法性能对比实验结果
Tab. 1 Results of comparative experiments of algorithm performance

数据集	算法	mAP@0.5/%	mAP@0.5 : 0.95 /%	参数量/10 ⁶	GFLOPs
工程车遥感数据集	YOLOv5	80.7	43.8	2.5	7.1
	YOLOv6	88.8	46.0	4.2	11.8
	YOLOv8n	92.2	58.6	3.0	8.1
	YOLOv10	93.7	58.9	2.7	6.7
	本文算法	95.8	61.5	3.4	8.4
NWPU VHR-10	YOLOv5	83.6	50.2	2.5	7.1
	YOLOv6	83.1	51.5	4.2	11.8
	YOLOv8n	90.7	61.6	3.0	8.1
	YOLOv10	84.7	54.5	2.7	6.7
	本文算法	92.3	60.2	3.4	8.4

为进一步验证本文算法对小目标的检测效果，对不同算法在 NWPU VHR-10 数据集中交通工具类小目标的检测精度进行对比，结果如表 2 所示。在 NWPU VHR-10 数据集交通工具类别中，本文算法较 YOLOv8n 算法的 mAP@0.5 提高了 3.5%，mAP@0.5 : 0.95 提高了 0.2%，且检测精度均优于

其他算法，表明本文算法对小目标具有较高的检测精度。

表 2 交通工具检测精度对比实验结果
Tab. 2 Results of comparative experiments of vehicle detection accuracy

数据集	算法	mAP@0.5/%	mAP@0.5 : 0.95 /%	参数量/10 ⁶	GFLOPs
NWPU VHR-10 (交通工具类)	YOLOv5	65.9	32.4	2.5	7.1
	YOLOv6	70.0	36.6	4.2	11.8
	YOLOv8n	87.1	54.1	3.0	8.1
	本文算法	90.6	54.3	3.4	8.4

2.3 消融实验

为验证所有改进措施的有效性，对分别添加不同改进模块的 YOLOv8n 算法进行对比。使用工程车遥感数据集和 NWPU VHR-10 数据集分别对每种算法训练 200 个轮次，实验结果如表 3 所示。其中，粗体数字表示每列的最优取值。YOLOv8n-GAM 为引入双层注意力机制改进后的算法；YOLOv8n-Focal_WIoU 为优化损失函数后的改进算法；YOLOv8n-GAM-Focal_WIoU 算法融合了上述所有的改进模块。

实验结果表明：在工程车遥感数据集中，YOLOv8n-GAM 较原模型的 mAP@0.5 提高了 1.7%，mAP@0.5 : 0.95 提高了 0.2%；YOLOv8n-Focal_WIoU 较原模型的 mAP@0.5 提高了 1.6%，mAP@0.5 : 0.95 提高了 1.9%；当添加所有改进模块后，YOLOv8n-GAM-Focal_WIoU 算法的 mAP@0.5 和 mAP@0.5 : 0.95 值最大，表明改进模

表 3 消融实验结果
Tab. 3 Results of ablation experiment

数据集	YOLOv8n	GAM	Focal_WIoU	mAP@0.5/%	mAP@0.5 : 0.95/%	参数量/10 ⁶	GFLOPs
工程车遥感数据集	√	—	—	92.2	58.6	3.0	8.1
	√	√	—	93.9	58.8	3.4	8.4
	√	—	√	93.8	60.5	3.4	8.4
	√	√	√	95.8	61.5	3.4	8.4
NWPU VHR-10	√	—	—	90.7	61.6	3.0	8.1
	√	√	—	90.9	61.8	3.4	8.4
	√	—	√	91.8	61.0	3.4	8.4
	√	√	√	92.3	60.2	3.4	8.4

块能够有效提升算法的检测精度。同样, 在 NW-PU VHR-10 数据集中, YOLOv8n-GAM、YOLOv8n-Focal_WIoU、YOLOv8n-GAM-Focal_WIoU 较原模型的 mAP@0.5 分别提升了 0.2%、1.1% 和 1.6%, 但 mAP@0.5 : 0.95 除 YOLOv8n-GAM 之外均有所下降。综上所述, 在依次添加改进模块后, 算法性能整体有所改进, 对目标的检测精度总体提高, 证明了各项改进措施的有效性。

添加不同改进模块的 YOLOv8n 算法在工程车

数据集和 NWPU VHR-10 数据集上的实验可视化结果如图 5 所示。其中, 图上的矩形框表示目标定位框, 上方字母表示该检测目标的分类类别, 数字表示目标检测的置信度。从图 5 可以看出, 本文算法对尺寸较小的目标具有较好的检测精度, 算法能够准确识别图像中的小尺寸目标, 对比原模型的目标检测置信度显著上升, 解决了因目标信息不足而导致的漏检问题, 证明了本文模型的有效性。




图 5 图片检测结果

Fig. 5 Image detection results

3 结论

为了解决遥感图像小目标特征信息弱、难易样本不平衡带来的漏检和检测不稳定问题, 以目前主流的 YOLOv8n 算法作为基线算法, 针对性地引入通道及空间双层注意力机制, 增强小尺寸目标特征提取能力, 同时引入一种更加关注难以分类样本的损失函数, 使改进后的算法更适用于遥感小目标检测应用场景。在工程车遥感数据集和 NWPU VHR-10 数据集上的对比实验和消融实验结果表明, 对比基线算法, 本文算法在小目标检测精度上具有显著提高。同时, 添加不同改进模块的 YOLOv8n 算法在 2 个数据集上的实验可视化结果表明, 本文算法能够准确识别图像中的小尺寸目标, 对比原模型的目标检测置信度有显著上升。但当前的研究仅针对于可见光遥感图像进行了实验验证, 算法的通用性有限, 且模型相对复

杂。后续, 将进一步对算法进行优化, 使用不同类型的遥感图像数据集对其进行实验验证, 以提高算法的通用性; 同时, 对算法的轻量化设计进行研究, 使算法便于部署在资源受限的平台上, 从而更好地满足军事应用需求。

参考文献

- [1] 赵永强, 饶元, 董世鹏, 等. 深度学习目标检测方法综述[J]. 中国图象图形学报, 2020, 25(4): 629-654.
ZHAO Y Q, RAO Y, DONG S P, et al. Survey on deep learning object detection[J]. Journal of Image and Graphics, 2020, 25(4): 629-654.
- [2] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述[J]. 电子学报, 2020, 48(3): 590-601.
LIU Y, LIU H Y, FAN J L, et al. A survey of research and application of small object detection based on deep learning[J]. Acta Electronica Sinica,

- 2020, 48(3): 590-601.
- [3] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 779-788.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[EB/OL]. (2016-09-17)[2024-07-17]. <http://arxiv.org/abs/1512.02325>.
- [6] LIM J S, ASTRID M, YOON H J, et al. Small object detection using context and attention [C]//2021 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC). Piscataway, NJ, USA: IEEE, 2021: 181-186.
- [7] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [8] BAI Y C, ZHANG Y Q, DING M L, et al. SOD-MTGAN: Small object detection via multi-task generative adversarial network[C]//European Conference on Computer Vision. Cham: Springer, 2018: 210-226.
- [9] RABBI J, RAY N, SCHUBERT M, et al. Small-object detection in remote sensing images with end-to-end edge-enhanced GAN and object detector network[J]. Remote Sensing, 2020, 12(9): 1432.
- [10] KISANTAL M, WOJNA Z, MURAWSKI J, et al. Augmentation for small object detection[EB/OL]. (2019-02-19)[2024-07-17]. <http://arxiv.org/abs/1902.07296>.
- [11] ZOPH B, CUBUK E D, GHIASI G, et al. Learning data augmentation strategies for object detection[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2020: 566-583.
- [12] ZENG N Y, WU P S, WANG Z D, et al. A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3507014.
- [13] LIU Y C, SHAO Z R, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions[EB/OL]. (2021-12-10)[2024-07-17]. <https://arxiv.org/abs/1512.02325>.
- [14] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42: 318-327.
- [15] CHO Y J. Weighted intersection over union (wIoU) for evaluating image segmentation[J]. Pattern Recognition Letters, 2024, 185: 101-107.
- (编辑: 刘建民)