

文章编号: 1671-7449(2026)03-0404-09

J. Test Measur. Technol., 2026, 40(3): 404-412.

多模块优化的轻量化YOLOv5s破片检测方法

张恒菠, 黄晋英*, 范振芳, 朱少鹏

(中北大学 机械工程学院, 山西 太原 030051)

摘要: 针对爆炸破片检测中目标微小密集、形态多变、环境干扰, 及现有深度学习方法计算复杂度高、难以部署于边缘设备的问题, 提出一种基于多模块协同优化的轻量化YOLOv5s(EGM-YOLOv5s)检测方法。该方法旨在同时解决小目标表征弱、模型冗余度高、定位精度不足三大问题。首先, 针对小样本破片数据集局限, 设计融合几何变换与噪声模拟(沙尘、光电干扰)的多模态数据增强策略以提升模型泛化性与鲁棒性。其次, 在算法架构层面进行三重针对性优化: 在骨干网络末端嵌入高效多尺度注意力模块, 通过跨通道交互与空间特征聚合强化微小破片纹理特征提取能力; 将颈部网络标准C3结构替换为C3Ghost模块, 利用轻量化特征重参数化技术显著降低计算复杂度与参数量; 在检测头引入最小点距交并比(MDPIoU)损失函数, 通过直接优化预测框角点距离提升小目标定位精度。实验结果表明, EGM-YOLOv5s模型在边缘级GPU(GTX1650)设备上, 于靶板破片数据集上的 mAP_{50} 检测精度为93.7%, 检测帧率为47.4帧/s。相较于原始YOLOv5s, 速度提升80.9%, 计算量降低10.8%, 模型参数量降低8.7%。该方案可有效平衡精度与速度, 显著降低对高性能硬件的依赖, 为在边缘计算设备上部署高实时性爆炸毁伤评估系统提供有效的轻量化模型支撑, 并验证其在动态爆炸毁伤现场实时评估场景的工程适用性。

关键词: YOLOv5s; 目标检测; 破片识别; 高效多尺度注意力

中图分类号: TP391.4

文献标识码: A

DOI: 10.62756/csjs.1671-7449.2026045

引用格式: 张恒菠, 黄晋英, 范振芳, 等. 多模块优化的轻量化YOLOv5s破片检测方法[J]. 测试技术学报, 2026, 40(3): 404-412.

ZHANG Hengbo, HUANG Jinying, FAN Zhenfang, et al. A lightweight YOLOv5s fragment detection method based on multi-module optimization[J]. Journal of Test and Measurement Technology, 2026, 40(3): 404-412.

A Lightweight YOLOv5s Fragment Detection Method Based on Multi-Module Optimization

ZHANG Hengbo, HUANG Jinying*, FAN Zhenfang, ZHU Shaopeng

(School of Mechanical Engineering, North University of China, Taiyuan 030051, China)

Abstract: In response to the challenges of detecting explosive fragments, such as small size, dense distribution, diverse shapes, and significant environmental interference, as well as the high computational complexity and difficulty in deploying existing deep learning methods on edge devices, a lightweight YOLOv5s detection framework is proposed based on multi-module collaborative optimization (EGM-YOLOv5s). The aim is to simultaneously address three major issues: weak representation of small targets, high model redundancy, and

【收稿日期】2025-07-14

【基金项目】山西省研究生科研创新资助项目(2024KY574); 山西省基础研究计划资助项目(202403021212143)

【作者简介】张恒菠(2001—), 男, 硕士生, 主要从事机器视觉和目标检测研究。E-mail: 1806680570@qq.com。

*【通信作者】黄晋英(1971—), 女, 教授, 博士, 主要从事结构动力学分析、检测与控制、故障诊断与健康管理研究。E-mail: jyhuang@nuc.edu.cn。

insufficient localization accuracy. Firstly, to overcome the limitations of small sample fragment datasets, a multimodal data augmentation strategy integrating geometric transformations and noise simulation (dust and photoelectric interference) is designed to enhance the model's generalization and robustness. Secondly, three targeted optimizations are implemented at the algorithm architecture level: an efficient multi-scale attention module is embedded at the end of the backbone network to enhance the extraction of texture features of small fragments through cross-channel interaction and spatial feature aggregation; the standard C3 structure in the neck network is replaced with the C3Ghost module, significantly reducing computational complexity and parameter count through lightweight feature reparameterization; and a minimum point distance intersection over union loss function is innovatively introduced in the detection head to improve the localization accuracy of small targets by directly optimizing the distance between the corner points of the predicted bounding boxes. Experiments show that the EGM-YOLOv5s model achieves a detection accuracy of 93.7% mAP50 and a high detection frame rate of 47.4 fps on an edge-level GPU (GTX1650) device using the target plate fragment dataset. Compared with the original YOLOv5s, the speed is increased by 80.9%, the computational complexity is reduced by 10.8%, and the model parameters are reduced by 8.7%. This solution effectively balances accuracy and speed, significantly reducing the reliance on high-performance hardware, providing an effective lightweight model support for deploying high real-time explosive damage assessment systems on edge computing devices, and verifying its engineering applicability in real-time assessment scenarios of dynamic explosive damage sites.

Key words: YOLOv5s; object detection; fragment recognition; efficient multi-scale attention

0 引言

现代化战争对武器精确打击与毁伤效应评估的快速性、智能化需求日益提升,使得爆炸效应评估变得至关重要。爆炸产生破片是毁伤目标的主要机制之一,其毁伤效能主要由区域内有效破片数量决定^[1]。破片场参数是对武器的作战效能以及打击效果研究的核心内容,其中,破片数量是评估战斗部威力与目标毁伤评估的关键指标^[2]。爆炸冲击产生的破片,由于飞散范围、速度及着靶角度的不同,常在靶板上形成形态各异、目标区域小且分布密集的破片区。精确统计靶板上的破片分布数量是衡量爆炸物毁伤能力的核心环节。

目前,针对破片分布数量的统计策略主要包含两类。其中,传统方法需依赖人工手动记录,在处理海量破片数据时效率不足,破片检测的实时性差,检测精度较低,难以达到高效与高精度的双重标准^[3]。另一类是基于人工智能的学习算法。在如今计算机性能高速发展的时代,机器学习与深度神经网络技术在图像分类、目标检测和语义分割等任务领域得到了广泛应用^[4-6]。在深度学习目标检测算法中,主流的方法包括基于候选区域的算法(如 Faster R-CNN^[7])和基于回归的算

法(如 YOLO 算法、单激发探测器^[8-9])。近年来,Wei 等^[10]采用 Mask R-CNN 方法定位量化混凝土表面坑洞,精度达到 90.08%;向雷等^[11]在城市道路的障碍物检测中使用改进的 YOLOv8 算法,平均精确率达到 97.12%;雷江波等^[12]在实现破片飞行过程定位时,使用了 Faster R-CNN 结合摄像的方法;魏琦等^[13]对 SSD 算法进行改进,实现了靶板破片定位检测精度 89.82%,但未解决毁伤区域关键几何信息量化问题。尽管上述方法能够取得较好的检测效果,但其普遍依赖于大规模、高质量的数据集,会造成上述模型计算量大,对计算硬件性能的要求较高。此外,这些方法在应对小目标时还存在定位精度不足、漏检率较高及检测速度实时性差等问题。

本文针对爆炸破片检测中存在的目标区域特征弱、易受环境干扰、小尺寸检测精度不足以及主流深度学习对设备的性能要求较高等问题,提出一种多模块优化的 YOLOv5s 检测方法。针对破片图像数据集采集困难,且易受光照、沙尘干扰的特点,本文设计了数据增强方案用于扩充数据集,同时对 YOLOv5s 框架进行三重改进:1) 主干网络嵌入高效多尺度注意力(Efficient Multi-scale Attention, EMA)模块,通过跨维度交互机制强化模型对微小破片纹理特征的提取能力;

2) 颈部网络采用C3Ghost模块替代标准C3结构, 利用轻量化特征重参数化技术计算复杂度; 3) 将检测头CIoU损失函数更换为最小点距交并比(Minimum Point Distance Intersection over Union, MPDIoU)损失函数, 通过边界框最小点距优化策略提升对小目标的定位能力, 改进后的模型简称为EGM-YOLOv5s。

1 多模态数据增强

本文使用高清相机对现场爆炸后的结果进行数据采集。因爆炸破片数据集规模受限, 原始数据仅26张图像, 本文采用多模态数据增强方法构建训练样本, 其核心原理在于通过模拟破片分布的几何随机性与战场环境的物理干扰, 分别针对性地提升模型的泛化性与鲁棒性。

在数据增强过程中, 为确保增强样本的多样性与分布合理性, 本文采用了多轮随机组合增强策略, 每张原始图像在20轮增强中随机应用至少一种变换。为了提升泛化性, 采用镜像翻转、随机旋转及平移等几何变换以打破破片在图像中的位置与角度先验, 使模型学习其本质形态特征, 而非记忆偶然出现的空间构型, 从而扩展模型对破片空间分布的认知范围。为了增强鲁棒性, 扩充样本中注入了高斯/泊松噪声, 进行了亮度调整并引入Cutout遮挡以模拟战场物理干扰。这些操作在像素层面重构了沙尘遮蔽、光电噪声及光照剧变等复杂战场环境, 使模型在训练中学会忽略此类扰动, 聚焦于更具鉴别力的特征。增强后的数据集在目标尺度、位置、旋转角度、噪声类型等方面呈现出较高的多样性, 可有效模拟真实战场环境中破片分布的复杂场景。

为进一步控制由小数据集带来的过拟合风险, 增强过程中引入Cutout随机遮挡与亮度抖动, 使模型不过度依赖局部特征。同时, 在训练阶段采用早停机制与交叉验证, 确保模型在验证集上性能稳定, 避免对增强样本的过度记忆。

最终通过该策略生成520张样本, 为保障评估的客观性与泛化能力, 数据集被严格划分: 首先, 始终保留40张未参与训练和验证的增强图像作为隔离测试集; 随后, 将增强后剩余的480张图像按8:2的比例随机划分为训练集与验证集。此种划分方式确保了训练与验证均基于增强数据, 而最终的模型性能则在一个完全独立、未经任何

训练的“干净”测试集上进行客观评估。具体增强参数见表1, 样本示例如图1所示。

表1 数据增强策略与参数配置

Tab. 1 Data augmentation strategy and parameter configuration

增强类型	参数设置	目标
噪声	方差	提升模型抗噪声干扰能力
旋转	角度	模拟破片多角度冲击场景
亮度调整	融合权重	增强光照鲁棒性
Cutout 遮挡	方形区域边长像素	防止模型过拟合局部特征
平移	横向/纵向偏移量	模拟破片随机性分布位置




图1 扩充后数据集

Fig. 1 Expanded dataset

2 目标检测算法

2.1 算法选择

目前, ultralytics YOLO发布的文件中指出, YOLOv5、YOLOv8、YOLOv9、YOLOv10、YOLOv11在目标检测方面各有优势。其中, YOLOv5采用分层解耦设计, 其核心组件具有高内聚性: 骨干网络由标准CBS与C3模块堆叠构成, 末端SPPF层提供多尺度特征融合, 颈部网络通过上采样与拼接操作实现特征金字塔融合, 检测头采用解耦式分类与回归分支。YOLOv5总体模块功能边界清晰, 且允许针对特定瓶颈进行局部改进。相较之下, YOLOv8-v11在架构设计、训练策略或特定任务精度上有所提升, 但其结构更加复杂或耦合度更高, 与轻量化需求相矛盾, 且对设备的计算能力要求更高。YOLOv8引入的C2f模块耦合了跨阶段特征交互与梯度流优化, 结构复杂性显著增加, 若对其进行轻量化改造, 需

重构特征传播路径,引入不可控的计算偏移风险。YOLOv9的核心创新在于可编程梯度信息,主要作用于训练阶段的信息流优化,对最终模型的部署以及推理效益并无增益效果。YOLOv10提出的无NMS训练技术尚未在密集小目标场景中充分验证,且其基础模型结构复杂度过高。YOLOv11的核心技术在于数据驱动的预训练范式革新与知识蒸馏机制优化,其模型依赖大规模的图像进行预训练,在小样本的破片场景下容易产生过拟合,同时其卷积运算依赖专用算子。综上所述,对于资源预算紧张或需要在边缘设备上快速部署的项目,YOLOv5是最好的选择。

YOLOv5在架构开放性、改进潜力与任务适配性上的优势,使其成为边缘导向型破片检测模

型优化的更佳载体。因此,本文基于YOLOv5s算法进行改进,在保证破片识别精度的同时减少网络的参数量,使网络更加轻量化,以提高其在边缘计算设备中的实用性。

2.2 YOLOv5算法改进

本文基于YOLOv5s提出一种改进模型:在骨干网络引入EMA模块,强化对微小破片特征的捕捉能力;颈部网络采用C3Ghost模块替代标准C3结构,在减少网络参数量的同时保持特征融合效率;设计MDPIoU损失函数,通过直接优化预测框角点距离,使其对小目标的定位精度得到提高。EGM-YOLOv5的网络结构如图2所示。




图2 EGM-YOLOv5s结构

Fig. 2 Architecture of improved YOLOv5

2.2.1 骨干网络优化

在破片检测任务中,主要面临破片目标尺寸微小、形态不规则及对环境干扰敏感度高三大核心挑战。传统注意力机制,如SE、CBAM等在处理此类复杂场景时存在局限性。SE的通道压缩导致特征损失,CBAM的空间感知能力不足,Non-local等全局注意力计算量过大,在边缘设备中难以实现^[14]。基于上述问题,本文选择EMA模块加入到骨干网络中。

EMA注意力模块是一种基于多尺度特征交互的设计,其核心创新在于通过维度重组策略将部分通道信息转移至批量维度,形成并行的分支结构^[15]。该机制在维持原始通道完整性的前提下,通过构建多个独立计算路径实现特征的多维度解析,同时在分支网络间建立分区域的通道交互机制,促使空间语义特征在不同特征组之间实

现均衡分布。这种策略在确保通道信息完整保留的同时优化计算路径,控制运算复杂度,避免了传统通道压缩方法引发的特征表达能力下降问题,从而在计算效率与模型性能间取得更优平衡。EGM-YOLOv5网络中的EMA模块结构如图3所示。

EMA模块在特征分组阶段将输入图像的通道分为多份,使用3个并行子网络。其中,2个并行网络分别将被通道分组后的图像进行X方向池化与Y方向池化,然后,使用与CA中的 1×1 卷积相同的卷积操作,最后,使用乘法将2个通道捕捉的特征聚合在一起,可以称作 1×1 网络;在第3个网络中仅使用1个 3×3 卷积核,可以称作 3×3 网络。前者通过2个空间方向捕获特征,后者捕获局部跨通道特征关系,这样可以将空间结构信息保留在信息通道中,显著提升对沙尘遮挡与光照干扰的适应性。




图3 主干网络中的EMA模块

Fig. 3 EMA module in backbone network

2.2.2 颈部网络轻量化

YOLOv5s的颈部模块作为主干网络与检测头的连接枢纽,通过多尺度特征融合增强模型对多尺寸目标的检测能力。核心组件C3模块在颈部网络中的计算量占比约为60%~70%,这意味着C3模块是颈部的主要计算来源,对整体性能有显著影响。

C3模块由3个Conv模块和1个Bottleneck模块构成,通过堆叠结构提升网络深度与感受野,Conv模块确保局部细节信息完整保留。Bottleneck模块通过卷积层提取空间通道特征,配合批量归一化层稳定数据分布,提升训练效率,采用SiLU激活函数增强非线性表达能力。但批量归一化层依赖小批量统计的特性会显著增加计算负荷和内存消耗,不利于在边缘计算设备的部署,所以需对网络结构进行轻量化改进,即对C3模块优化。

本文使用C3Ghost替换YOLOv5s颈部网络中的4个C3模块。C3Ghost模块是在C3结构基础上优化而来,主要包含2个GhostConv层和1个残差连接块。C3Ghost基于GhostNetV1思想,利用破片特征图的高相似性进行轻量化重构。GhostNetV1算法从特征图方面入手,认为众多特征图的部分冗余性及它们之间的相关性可以作为轻量化的切入点。在特征提取过程中会存在极为相似的特征图,可以认为它们之间存在冗余^[16]。但是,冗余特征图可能是一个优秀神经网络模型的重要组成部分,它们有助于模型学习更全面的图像特征。GhostNet主要核心为Ghost模块^[17],如图4所示,其设计依赖于两个基本操作:1)通过

标准的卷积生成原始特征图,对于输入 X 和卷积核 W ,真实卷积表示为

$$X_{\text{real}} = W_{\text{real}} X_{\text{o}} \quad (1)$$




图4 颈部网络中的Ghost模块

Fig. 4 Ghost module in neck network

2) 通过一个小的 1×1 卷积核生成伪特征图,伪卷积表示为

$$X_{\text{ghost}} = W_{\text{ghost}} X_{\text{o}} \quad (2)$$

最后,将真实特征图与伪特征图拼接,得到Ghost模块的输出为

$$Y = \text{concat}(X_{\text{real}}, X_{\text{ghost}}) \quad (3)$$

Ghost模块的核心设计理念是使用较少的参数量与计算资源来生成丰富的特征图,从而压缩模型的计算复杂度和存储量,同时,在不损失太多精度的前提下减少参数量,使网络更加轻量化。

2.2.3 检测头优化

在实际目标检测任务中,当待检测目标尺寸过小时,传统 IoU 指标对预估框与实际框的微小位置偏差过于敏感,计算公式如式(4)所示,且 CIoU 损失函数中通过中心点距离和长宽比约束的间接优化方式难以有效捕捉微小目标的精确位置特征^[18]。

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(B_{\text{gt}}, B_{\text{pred}})}{C^2} + \alpha v, \quad (4)$$

$$\text{IoU} = \frac{B_{\text{gt}} \cap B_{\text{pred}}}{B_{\text{gt}} \cup B_{\text{pred}}}, \quad (5)$$

$$\alpha = \frac{v}{(1 - \text{IoU}) + v}, \quad (6)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{W_{\text{gt}}}{h_{\text{gt}}} - \arctan \frac{W_{\text{pred}}}{h_{\text{pred}}} \right)^2, \quad (7)$$

式中: IoU 为预估框与实际框的重叠度; B_{gt} 和 B_{pred} 分别为预估框与实际框的中心点参数; ρ 为预估框与实际框的间距偏差; c 为覆盖预估框和实际框的最小外接矩形对角线长度; α 为调节参数; v 为用来检验长宽比的匹配程度; W_{gt} 和 h_{gt} 分别为实际框的横向与纵向尺寸; W_{pred} 和 h_{pred} 分别为预估框的宽和高。

针对小目标检测中传统 IoU 指标对位置敏感和 CIoU 间接优化效果不足的问题,本文引入 MPDIoU 损失函数,其核心思想是直接最小化预测框与真实框的左上角和右下角点距,计算公式为

$$L_{\text{MPDIoU}} = 1 - \text{MPDIoU}, \quad (8)$$

$$\text{MPDIoU} = \text{IoU} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2}, \quad (9)$$

$$d_1^2 = (x_1^{\text{pred}} - x_1^{\text{gt}})^2 + (y_1^{\text{pred}} - y_1^{\text{gt}})^2, \quad (10)$$

$$d_2^2 = (x_2^{\text{pred}} - x_2^{\text{gt}})^2 + (y_2^{\text{pred}} - y_2^{\text{gt}})^2, \quad (11)$$

式中: d_1 和 d_2 分别为预测框与真实框左上角和右下角之间的欧式距离; w 和 h 为输入图片的横向尺寸与纵向尺寸; $(x_1^{\text{pred}}, y_1^{\text{pred}})$ 和 $(x_2^{\text{pred}}, y_2^{\text{pred}})$ 为预测框的起始顶点坐标和终止顶点坐标; $(x_1^{\text{gt}}, y_1^{\text{gt}})$ 和 $(x_2^{\text{gt}}, y_2^{\text{gt}})$ 为实际框的起始顶点坐标与终止顶点坐标。

3 实验方法与结果

3.1 实验配置与参数

为了验证本文提出的 EGM-YOLOv5s 模型在边缘计算场景的性能,实验采用满足边缘计算定义的移动级计算硬件平台: Intel Core i5 9300H CPU 与 NVIDIA GeForce GTX1650 (4 GB 显存) 的 GPU, 软件环境基于 PyTorch1.12 和 CUDA11.3。相关参数设置如下: 训练周期为

200, 批次大小(batchsize)设置为 2, 初始学习率设为 0.005, 权重衰减系数 0.000 5, 输入图像的分辨率为 416×416 像素。上述参数设置综合考虑了硬件限制与训练稳定性。在 4 GB 显存的硬件条件下,较小的批次大小是能够成功加载模型并进行训练的必要条件。然而,小批次训练会带来梯度估计噪声大、训练过程不稳定的风险。为抵消这一影响,本实验选择了相较于 YOLOv5 官方更加保守的初始学习率 0.005。降低学习率可以有效减小参数更新步长,抑制因小批次内梯度方差过大而导致的优化路径震荡,确保训练过程平稳收敛。权重衰减系数选择了 YOLOv5 系列模型经大量实验验证的默认值 0.000 5,防止在小规模破片数据集上过拟合。

将构建的独立数据集中的 480 张图像按 8:2 的比例随机分为训练集和验证集,将未参与训练与验证的 40 张图像数据作为测试集,同时测试集全程隔离于训练和验证过程,确保评估客观性。


3.2 改进模型与原模型综合评估

将 EGM-YOLOv5s 模型与 YOLOv5s 模型进行比较,得到的检测结果可视化对比图如图 5 所示。由图 5 可知,两种模型均可检测出目标区域。另外,表 2 列出了原 YOLOv5s 模型及本文提出的 EGM-YOLOv5s 模型的相关识别参数。其中, $F1\text{-score}$ 为检测的精确率和召回率的调和平均数;置信度为模型对预测框中包含目标的信心程度;平均精度均值(mean Average Precision, mAP)中 $mAP50$ 表示交并比阈值大于 0.5 的 mAP 值, $mAP50\text{-}95$ 表示交并比阈值为 0.5~0.95 的 mAP 值;帧率表示模型在硬件上的运行速度;计算量为每秒浮点运算次数。


由表 2 可以看出,与 YOLOv5s 模型相比,EGM-YOLOv5s 模型的计算量压缩至 14.1 GFLOPs,下降了 10.8%,参数量为 6.1 M,降低了 8.7%。因此,EGM-YOLOv5s 模型在保证检测准确率的前提下,降低了帧率和模型的复杂度,提高了检测速率,更加适用于边缘性计算机。另外,EGM-YOLOv5s 模型 $mAP50$ 为 0.937,较改进前模型低了 0.5%,这一差异主要源于轻量化过程中部分细节特征的损失。但 EGM-YOLOv5s 模型 $F1\text{-score}$ 为 0.92,较 YOLOv5s 提升 1.0%,意味着在较低置信度阈值(0.543)下,EGM-YOLOv5s 模型依然保持较高召回率,能够有效满足破片区域检测等对漏检高度敏感任务的应用需求。尽管 YOLOv5s 在精度和关键

类别检测上表现更优,适用于高精度需求场景,但 EGM-YOLOv5s 模型借助边缘计算框架,在速度和

精度之间取得了更好的平衡,该优化模型可为野外环境的检测任务提供更可靠、更轻量的解决方案。



(a) YOLOv5s 识别图



(b) EGM-YOLOv5s 识别图

图 5 改进前后的参数对比

Fig. 5 Comparison of parameters before and after improvement

表 2 改进前后对比实验

Tab. 2 Comparison experiments before and after improvement

模型	<i>F1-score</i>	置信度	<i>mAP</i> 50	<i>mAP</i> 50-95	帧率/(帧·s ⁻¹)	计算量/GFLOPs	参数量/M
YOLOv5s	0.91	0.630	0.942	0.378	26.191	15.8	6.673
EGM-YOLOv5s	0.92	0.543	0.937	0.367	47.369	14.1	6.092

3.3 消融实验

为验证 EMA 模块、C3Ghost 模块、MPDIoU 函数的独立或联合使用时的作用,本文设计了如

表 3 所示的消融实验,其中模型 A、B、C 分别代表在骨干网络添加 EMA 机制、将颈部 C3 替换为 C3Ghost、将头部 IoU 损失函数替换为 MPDIoU 损失函数这 3 种改进方法。

表 3 消融实验结果

Tab. 3 Results of ablation experiment

实验模型	计算量/GFLOPs	参数量/M	<i>mAP</i> 50	<i>mAP</i> 50-95	帧率/(帧·s ⁻¹)
YOLOv5s	15.8	6.673	0.942	0.378	26.191
A	16.2	7.013	0.961	0.406	31.775
B	13.7	5.769	0.898	0.325	42.794
C	15.8	6.673	0.953	0.382	26.353
A+B	14.1	6.092	0.912	0.343	43.928
A+C	15.8	7.013	0.971	0.412	26.886
B+C	13.7	5.769	0.901	0.343	42.674
EGM-YOLOv5s	14.1	6.092	0.937	0.367	47.369

由表 3 可以看出,EMA 模块在少量增加模型参数的同时,提升了 *mAP*50 和帧率,分别提升了 2.1% 和 4.4 帧/s。将颈部的 C3 模块替换为 C3Ghost 模块后,在降低模型参数量的同时,帧率提升了 16.6 帧/s,但 *mAP*50 下降了 4.4%。将 CIoU 损失函数替换为 MDPIoU 函数后, *mAP*50 提高了 1.3%,帧率基本不变,EMA 模块和 C3Ghost 模块、MDPIoU 函数分别同时部署时,前者取得了小幅度的速度提升和 *mAP*50 下降,后者在 *mAP*50 和帧率方面均取得了小幅度的提升。但 EMA 模块和 MDPIoU 函数

的同时部署时能可观地提高 *mAP*50。所有方案的同时应用虽 *mAP*50 下降了 0.5%,但为模型带来了 17.18 帧/s 的运行速度提升。

上述结果表明,模块之间的相互作用对模型的最终性能产生了决定性影响。实验模型(B)中虽有限降低了参数量及计算复杂度,但其特征重参数化过程难以完美复现标准卷积所提取的破片的全部复杂纹理模式,导致特征表达能力下降,这是引起 *mAP* 显著降低的主要原因。而实验模型(A+B)中 EMA 模块通过在特征进入颈部轻量化之前先行强化和筛

选出重要特征,抵消掉了单独使用 C3Ghost 所带来的性能损失。

实验模型(A+C)中的 EMA 模块负责提取并强化关键的破片特征,MPDIoU 损失函数基于这些特征精准地优化边界框的位置,从而达到了最高检测精度。实验模型(A+B+C)中 EMA 模块虽在模型的头部提供了优质输入,但颈部的 C3Ghost 的轻量化操作造成了部分特征信息的损失,其输出的特征信息对于 MPDIoU 损失函数效能受限,从而导致整体精度无法达到最优化,这一现象揭示了轻量化进程的内在权衡。本文改进的模型正是在此权衡下,以微小的精度代价换取了巨大的速度增益,最终实现了更适用于边缘设备的、速度与精度平衡的优化方案。

3.4 对比实验

为验证本文算法在破片检测方面的优越性,使用自制破片数据集,采用相同的实验环境,将 EGM-YOLOv5s 与多种主流检测算法进行对比,其中包括 YOLOv3、YOLOv5、YOLOv8 及二阶段算法 Faster R-CNN 与 SSD,实验结果如表 4 所示。其中, YOLOv5n 和 YOLOv8n 是分别为对应系列的纳米级版本,代表原生轻量化极限;此外,也将 MobileNetV3^[19]引入 YOLOv5s 中,替换主干网络,这是目前一种被广泛采用的网络轻量化方案。所有模型均在本文数据集上重新进行训练,确保评估的公平性。

表 4 与其他模型对比实验结果

Tab. 4 Comparison results with other models

模型	<i>mAP</i> 50	参数量/M	帧率/(帧·s ⁻¹)
SSD	0.923	24.372	19.446
Faster R-CNN	0.813	58.023	10.235
YOLOv3	0.917	61.434	25.677
YOLOv5s	0.953	6.673	26.191
YOLOv5n	0.912	1.436	23.267
YOLOv8n	0.942	3.013	22.462
YOLOv5s+MobileNetV3	0.924	5.253	31.652
EGM-YOLOv5s	0.937	6.092	47.369

根据表 4 可以得出,原始 YOLOv5s 模型在本文数据集上取得了最高的检测精度 95.3%,且其参数量和速度均显著优于 YOLOv3、SSD 及 Faster R-CNN 等早期模型,验证了其作为改进基准的优越性。虽然 EGM-YOLOv5s 模型精度下降,但仍优于多数模型。YOLOv5n 和 YOLOv8n 通过大幅减少网络宽度与深度实现轻量化, YOLOv5n 的参数量降至极低的 1.436 M,但精度损失较大; YOLOv8n 在参数量和精度方面取得了较好的平

衡,但其推理速度低于本文改进模型;替换 MobileNetV3 的方法有效降低了参数量,检测速度提高,但其检测精度也降低。

EGM-YOLOv5s 模型的 *mAP*50 为 93.7%,虽较 YOLOv8n 的检测精度下降了 0.5%,较 YOLOv5s 的检测精度下降了 1.6%,但优于其他轻量化方案,同时,其推理速度达到 47.369 帧/s,较基础 YOLOv5s 提升 80.9%。这一帧率远超其余对比模型,包括其他轻量化版本。该结果表明,本文改进的 YOLOv5 模型在可接受的精度损失范围内,实现了检测速度的显著提升,更适合边缘设备部署和实时检测任务。

4 结 论

本文针对爆炸毁伤评估中破片检测的目标微小、分布密集且环境干扰因素大,及边缘设备计算能力和内存容量小等问题,提出多模块协同优化的轻量化 EGM-YOLOv5s 检测模型。首先,鉴于破片原始数据集有限性,通过融合几何变换与光电干扰模拟的多模态数据增强,提升沙尘环境泛化性,增强模型的鲁棒性。其次,对原 YOLOv5s 神经网络进行了三重改进:引入 EMA 模块,用于强化对微小破片的纹理感知;使用 C3Ghost 模块替换颈部网络的 C3 模块,降低网络的计算量与复杂度,提升检测速率;将 CIoU 损失函数替换为 MDPIoU 函数,直接优化边界框角点距离提升小目标定位精度。最后,通过将 EGM-YOLOv5s 模型部署在边缘 GPU 设备上,验证了该模型的运算速度-检测精度的平衡性。结果表明,通过特征感知增强、网络结构轻量化、提高定位能力的 EGM-YOLOv5s 模型,在边缘设备上达到了精度损失与速度增益的最优化平衡。此外,该模型仍具有可优化空间,未来的研究可以延伸至多模态扩展,提升夜间及恶劣环境检测能力,多目标破片的识别及分类,以及开发对抗训练模块应对战场主动干扰。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors declare no relevant conflict of interests.

参考文献

- [1] 周家杰,孔德仁,徐春冬,等.阵列式破片速度及飞散特性一体化测量系统[J].电子测量技术,2022,45(12):133-140.
ZHOU Jiajie, KONG Deren, XU Chundong, et al.

- Array-type integrated measurement system for fragment velocity and scatter peculiarity[J]. Electronic Measurement Technology, 2022, 45(12): 133-140. (in Chinese)
- [2] 洪豆, 郑宇, 李文彬, 等. 破片战斗部杀伤面积影响规律研究[J]. 兵器装备工程学报, 2021, 42(5): 37-42.
- HONG Dou, ZHENG Yu, LI Wenbin, et al. Research on influence law of fragment warhead's killing area[J]. Journal of Ordnance Equipment Engineering, 2021, 42(5): 37-42. (in Chinese)
- [3] 陈曦, 翟红波. 基于图像的目标毁伤评估研究进展[J]. 兵器装备工程学报, 2024, 45(7): 224-234.
- CHEN Xi, ZHAI Hongbo. Image-based damage assessment: a review[J]. Journal of Ordnance Equipment Engineering, 2024, 45(7): 224-234. (in Chinese)
- [4] JENA B, SAXENA S, NAYAK G K, et al. Artificial intelligence-based hybrid deep learning models for image classification: the first narrative review[J]. Computers in Biology and Medicine, 2021, 137: 104803.
- [5] 杨甜甜, 郭大波, 孙佳. 基于多残差网络的遥感图像语义分割方法[J]. 测试技术学报, 2021, 35(3): 245-252.
- YANG Tiantian, GUO Dabo, SUN Jia. Remote sensing image semantic segmentation method based on multi-residual network[J]. Journal of Test and Measurement Technology, 2021, 35(3): 245-252. (in Chinese)
- [6] ZHANG Y, MA R, LIANG C. Road target detection algorithm based on improved YOLOv5 in UAV images[J]. Journal of Measurement Science and Instrumentation, 2024, 15(1): 128-139.
- [7] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [8] 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), 2016: 779-788.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multi-box detector[C]// European Conference on Computer Vision, Amsterdam, Netherlands, 2016: 11-14.
- [10] WEI F, YAO G, YANG Y, et al. Instance-level recognition and quantification for concrete surface bughole based on deep learning[J]. Automation in Construction, 2019, 107: 102920.
- [11] 向雷, 蒋文波. 改进YOLOv8的城市行车道路障碍物检测算法研究[J]. 电子测量技术, 2025, 48(1): 29-38.
- XIANG Lei, JIANG Wenbo. Research on improved YOLOv8 urban driving road obstacle detection algorithm[J]. Electronic Measurement Technology, 2025, 48(1): 29-38. (in Chinese)
- [12] 雷江波, 王泽民, 李静, 等. 基于Faster R-CNN的破片群图像目标检测研究[J]. 国外电子测量技术, 2021, 40(1): 70-74.
- LEI Jiangbo, WANG Zemin, LI Jing, et al. Research on target detection of fragment group images based on faster R-CNN [J]. Foreign Electronic Measurement Technology, 2021, 40(1): 70-74. (in Chinese)
- [13] 魏琦, 何子清, 王亚林, 等. 基于DenseNet和注意力机制的静爆场破片识别方法研究[J]. 兵器装备工程学报, 2023, 44(2): 259-265.
- WEI Qi, HE Ziqing, WANG Yalin, et al. Research on fragment identification of a static explosion field based on DenseNet and attention mechanism[J]. Journal of Ordnance Equipment Engineering, 2023, 44(2): 259-265. (in Chinese)
- [14] 冯小丹, 云利军, 高海峰, 等. 机器视觉注意力机制研究综述[J]. 云南民族大学学报(自然科学版), 2025, 34(4): 453-463.
- FENG Xiaodan, YUN Lijun, GAO Haifeng, et al. A review of research on attention mechanisms in machine vision[J]. Journal of Yunnan Minzu University (Natural Sciences Edition), 2025, 34(4): 453-463. (in Chinese)
- [15] OUYANAG D, HE S, ZHAN J, et al. Efficient multi-scale attention module with cross-spatial learning [C]//ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2023: 1-5.
- [16] TANG Y, HAN K, GUO J, et al. GhostNetV2: Enhance cheap operation with long-range attention[C]//36th International Conference on Neural Information Processing Systems, ACM, 2022: 9969-9982.
- [17] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 1577-1586.
- [18] WANG M L, LIU Z Y, ZHANG R, et al. MPDIoU: a loss for efficient and accurate bounding box regression [EB/OL]. [2025-05-13]. <https://arxiv.org/abs/2307.07662>.
- [19] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314-1324.