

文章编号:1007-2780(2026)05-0659-16

基于改进 YOLOv11n 的轻量化锥筒识别算法

李 奥¹, 王明武^{1*}, 王 楠¹, 谢 锐²

(1. 陕西理工大学 机械工程学院, 陕西 汉中 723001;

2. 陕西汉江机床有限责任公司, 陕西 汉中 723301)

摘要:针对当前市面上锥筒回收装置自动化程度低、检测精度不足,且因参数量大造成移动端设备部署困难等问题,提出了一种基于改进 YOLOv11n 的轻量化识别算法 RGLU-YOLOv11n。首先,结合 RepConv 和 TransNet 的 CGLU (Convolutional Gated Linear Unit) 重构 C3K2 模块,降低复杂模型复杂度并提高检测速度;其次,引入 Ghost 卷积和自适应下采样 (Adaptive Downsampling, ADown),设计一种轻量化的幽灵下采样模块 (Ghost-ADown),在保持特征丰富度的同时显著降低了下采样过程中的计算冗余;然后,引入一种轻量化共享卷积检测头 (Lightweight Shared Convolutional Detection, LSCD),在保持检测精度的同时实现模型轻量化,使模型更加适合部署在资源受限的边缘设备;最后,针对 CIoU 损失函数在检测时泛化性弱和收敛速度慢的问题,引入 Focaler-IoU 和 MPDIoU,设计 Focaler-MPDIoU 损失函数替代原有模型的损失函数,以提高模型精度并加快边界框回归速度。实验结果表明:该模型较基准模型 YOLOv11n 精确率、召回率、平均精度均值 mAP0.5 分别提升了 1.1%、1.4% 和 1.6%,参数量和模型存储体积显著降低 35.3% 和 41.5%,表明该模型在显著减少计算开销的同时,依旧维持了较高的识别准确率,符合移动端及嵌入式设备的部署需求。

关键词:锥筒检测;深度学习;多模块融合;轻量化模型;损失函数

中图分类号:TP391 文献标识码:A doi:10.37188/CJLCD.2026-0067 CSTR:32172.14.CJLCD.2026-0067

Lightweight cone detection algorithm based on an improved YOLOv11n

LI Ao¹, WANG Mingwu^{1*}, WANG Nan¹, XIE Rui²

(1. School of Mechanical Engineering, Shaanxi University of Technology, Hanzhong 723001, China;

2. Shaanxi Hanjiang Machine Tool Co. Ltd., Hanzhong 723301, China)

Abstract: To address the issues of low automation, insufficient detection accuracy, and difficulty in deploying on mobile devices due to large parameter counts in current cone recycling devices, this paper proposes a lightweight recognition algorithm named RGLU-YOLOv11n based on an improved YOLOv11n. First, RepConv and TransNet's CGLU (Convolutional Gated Linear Unit) are integrated to reconstruct the C3K2 module, reducing model complexity and improving detection speed. Second, Ghost convolution and adaptive downsampling (ADown) are introduced to design a lightweight Ghost-ADown module, which notably reduces computational redundancy during downsampling while preserving feature richness.

收稿日期:2026-04-06;修订日期:2026-04-16.

基金项目:陕西省服务地方专项科研计划(No. 22JC025)

Supported by Shaanxi Provincial Special Scientific Research Program Fund for Serving Local Development (No. 22JC025)

*通信联系人, E-mail: wangmingwu@163.com

Third, a Lightweight Shared Convolutional Detection (LSCD) head, is introduced to achieve model lightweighting while maintaining detection accuracy, making the model more suitable for deployment on resource-constrained edge devices. Finally, to address the issues of weak generalization and slow convergence of the CIoU loss function during detection, Focaler-IoU and MPDIoU are introduced to design a Focaler-MPDIoU loss function, replacing the original loss function to improve model accuracy and accelerate bounding box regression. Experimental results show that compared with the baseline YOLOv11n model, the proposed model achieves improvements of 1.1%, 1.4% and 1.6% in precision, recall and mAP@0.5, respectively, while reducing parameters and model size by 35.3% and 41.5%, respectively. These results demonstrate that the proposed model maintains high recognition accuracy while significantly reducing network computational load, meeting the deployment requirements for mobile and embedded devices.

Key words: cone detection; deep learning; multi-module fusion; lightweight model; loss function

1 引 言

近年来,国内高速公路的发展态势极为迅猛,其发展水平在世界范围当中稳居首位。随着城市化进程持续加快,道路网络愈发复杂,交通安全与道路维护逐渐成为交通管理部门关注的核心议题^[1]。在道路施工、潮汐车道管控、临时交通管制等诸多场景中,交通锥筒扮演着不可或缺的重要角色^[2]。目前,交通锥筒的布设与回收工作主要依赖人工完成,作业效率不仅低下,而且在高速公路等复杂环境下,工作人员的安全也无法得到保障。即便市面上已有交通锥筒自动收放设备问世,能够在一定程度上替代人工,但由于自动化程度不高、仍需人工干预,加之设备造价昂贵、维护使用成本高,导致这些装置尚未得到广泛应用^[3]。

近年来,智能交通系统中的视觉识别技术在交通设施管理领域取得了显著进展,但在交通锥筒收放装置的自动化研究方面尚有欠缺^[4]。为克服传统人工布设锥筒存在的效率低下和安全隐患缺点,学者们正积极探索将目标检测算法 YOLO(You Only Look Once)^[5-11]与自动控制系统相结合的技术路径,为实现交通锥筒收放作业的智能化、自动化提供了新的解决方案。Wang^[12]等提出一种交通锥筒收放系统,以轻量化 YOLOv5-Lite-s 构建网络模型,选用 ShuffleNet 当作主干网络,并将 Focus 模块和经剪枝优化的 C3 模块融合到一起,具备较高的运行效率,平均检测精度可达到 90%,但在特殊工作场景下检

测稳定性不足。Su^[13]等将 YOLOv4 和立体视觉技术相融合,使用双目摄像头以获取深度信息,达成对交通锥筒三维坐标的估计。该方式既提升了检测时的鲁棒性,又为自动化设备路径规划给出精确的空间定位数据,但双目视觉会增加系统计算负担。李旭^[14]等引入 Stem 模块和 EfficientNet-Lite 网络替换 YOLOv8 主干网络,使参数量从 3M 降到 1.37M,在减少锥筒漏检的同时大幅度压缩模型算量,但在复杂背景下目标的识别能力会有所降低。Katsamenis^[15]等构建一个专用于锥筒检测的数据集 TraCon,涵盖了不同环境条件下的样本。该数据集对 YOLOv5 模型展开训练,经过训练后的模型针对小目标检测时表现颇为出色,交并比(Intersection over Union, IoU)达到了 91.31%,切实验证了 YOLO 算法在实际应用场景中的有效性。综上,如何平衡算法检测精度与模型存储体积,使其能稳定部署于边缘设备,已成为锥筒检测算法面临的重要挑战。

针对以上问题,本研究提出基于改进 YOLOv11n 的轻量化识别算法 RGLU-YOLOv11n。首先,利用 RepConv 和 CGLU 模块对 C3K2 模块重构,提高模型检测速度;其次,设计 Ghost-ADown 下采样模块以减少冗余计算,并引入轻量级共享卷积检测头 Detect-LSCD 再次压缩模型体积;最后,在 Focaler-IoU 和 MPDIoU 基础上,设计出 Focaler-MPDIoU 损失函数替代原有模型的损失函数,提升模型的检测精度。

2 锥筒自动收放装置与视觉需求分析

锥筒自动收放装置主要安装于高速公路养护车辆或自动驾驶道路清理车。在施工区入口,装置需要快速将锥筒按预定间距布设;在施工结束后,需将锥筒逐一回收。由于施工区常存在车流干扰、光照变化、夜间作业等挑战,传统依赖人工遥控的操作方式效率低且存在安全隐患。因此,装置须具备自动视觉识别能力,实时检测锥筒的物理位置与空间方位,引导机械臂或传送机构完成抓取或释放动作。

锥筒自动收放设备是通过车辆的前进或者后退,由固定在车上的机械装置完成锥筒的抓取、输送、摆放等一系列动作,从而代替纯人工操作。其核心设备包括摄像头、锥筒识别算法嵌入设备、PLC控制器、锥筒抓取装置等。

锥筒自动收放设备作业状态调整为“收筒”时,四杆机构在电机驱动下将抓取装置下放至收筒高度,即位时触发下限位开关。此时锥筒检测定位算法开始运行,通过摄像头识别锥筒并将中心坐标实时传送至PLC,PLC根据坐标信息控制横向和纵向两个电机正反转,最终使抓取装置与交通锥筒的位置重合,在车辆行进过程中完成收筒工作。当作业状态调整为“放筒”时,驾驶员驾驶作业车辆向后行驶,锥筒检测定位算法通过摄像头获取锥筒中心坐标,并将坐标传送至PLC,PLC程序驱动电机控制抓取装置对准锥筒。当锥筒进入抓取范围时,夹爪前方的超声波传感器向PLC反馈电信号,而后控制夹爪动作的直流电动推杆夹紧锥筒,四杆机构电机反转将锥筒提升至上限位,作业人员取下锥筒即可完成回收作业。取下锥筒时,夹爪上方的红外传感器检测到人手后反馈电信号使电动推杆反向运动,夹爪张开。作业人员取下锥筒后,超声波传感器反馈电信号,四杆机构运动至下限位进行下次回收作业。锥筒识别算法在锥筒收放装置中充当着“眼睛”的职责,所以探索一种兼顾高精度与轻量化的锥筒识别算法具有重要意义。

将本研究算法应用于图1所示的锥筒收放机,部署该算法的移动设备固定于机械臂上方。当机械臂处于下限位时,算法启动识别工作,PLC根据识别到的锥筒位置调整机械臂的姿态。




图1 锥筒自动收放机工作示意图

Fig.1 Schematic diagram of the automatic cone tube reeling machine

3 YOLOv11网络模型改进

YOLOv11网络模型是目标检测领域的更新版本,网络结构及计算效率做了大量优化,相比于前代YOLOv8模型,其在检测精度和模型轻量化之间取得了更好的平衡^[16]。此外,YOLOv11引入了C3k2模块、SPPF模块和C2PSA模块,多尺度特征提取能力得到有效提升,比YOLOv11m参数量降低22%,在COCO数据集上达到了更高的平均精度均值(mAP)。同时,由于YOLOv11n具有较低复杂度的设计理念及较小尺度的特征图,在边缘设备上部署更为合适。

为使模型进一步轻量化,并提高实时性和检测精度,本研究所改进的YOLOv11n网络结构如图2所示,主要改进措施如下:

(1) 利用RepConv和CGLU对原始C3K2模块进行改进,得到的C3K2-RC模块结合了重参数和动态门控的独特设计,提升了模型的特征表达能力,在不同场景下实现模型轻量化。

(2) 结合Ghost卷积与自适应下采样方法,设计一种轻量化幽灵下采样层模块(GhostADown),从而通过减少冗余特征计算和合理的下采样,在保证特征多样性的前提下大幅降低计算量及参数量。

(3) 引入轻量级共享卷积检测头(Detect-LSCD),利用参数共享机制降低检测头计算量。

(4) 针对CIoU损失函数泛化性弱与收敛速度慢的问题,融合Focaler-IoU和MPDIoU设计出Focaler-MPDIoU损失函数,在提升检测精度的同时加速边界框回归收敛。




图3 模块结构示意图。(a) RepConv网络结构图;(b) CGLU结构图;(c) RC结构图。

Fig. 3 Schematic diagrams of the module structures. (a) RepConv network; (b) CGLU structure; (c) RC structure.

采用多分支结构,推理时无损融合为单卷积,同时CGLU始终以轻量门控方式动态调制通道特征。

3.2 G-ADown轻量化下采样模块

在目标检测任务中,冗余特征图有助于提升网络对重要特征的学习能力。一方面,交通锥筒检测中,多种类似的特征图不仅可提升网络对锥筒边缘的识别能力,使不同的光线或视角下都有较好的鲁棒性;还易于学习到不同大小的目标细节,如远处的小锥筒和近处的大锥筒。但另一方面,过多的冗余特征图又会给模型带来较重的计算负担。

为更好地发挥特征冗余部分作用以减少模型参数量,进一步使用GhostConv卷积^[20]搭建轻量化网络。GhostConv由两部分组成:一是主干路径,即普通的 3×3 卷积用于负责提取空间特征;二是幽灵路径,使用深度可分离卷积完成较为高效的线性计算。两部分输出相结合便形成新的特征图。GhostConv利用多个线性变换加强对原有特征信息的学习能力,以有利于后续模型融合时保持较高灵活性与可扩展性。

为平衡计算效率与特征丰富度,GhostConv模块通过比例因子 s 对输出特征图进行分配。输出特征图总数设为 N ,常规卷积负责生成 N/s 个本征特征图,剩余 $N - N/s$ 个特征图则由分组卷积通过线性变换衍生得到,即生成 $N/s \times (s - 1)$

个幽灵特征图。本研究中,输入/输出通道数均为8,比例因子 $s = 4$,GhostConv具体的结构如图4所示。




图4 GhostConv结构

Fig. 4 GhostConv structure

常规卷积首先生成两个本征特征图,基于本征特征图进行线性变换生成其余6个特征图,两部分特征图沿通道维度拼接而形成完整的输出特征图。该设计中,通过对本征特征图进行多次变换有效降低了常规卷积中特征冗余所引入的参数量,实现了计算效率与特征表达能力的协同优化。

ADown下采样层^[21]采用平均池化降低特征图尺寸,进而减少后续卷积的计算开销。在通道处理层面,该模块设计了两条并行路径:一组通过 3×3 标准卷积进行提取空间特征;另一组则先经过步长为2的 3×3 最大池化以减少空间尺寸并保留显著特征,随后通过一个 1×1 卷积调整通道。模型通过参数共享机制实现高效学习,在参

数量下降的同时提升计算效率。

本文集成 GhostConv 以及 ADown 的优点，采用 Ghost 卷积替换 ADown 中的普通卷积，进一步设计出轻量化幽灵下采样层(Ghost-ADown)。

Ghost-ADown 模块在保留高效采样结构的基础上，借助 GhostConv“先核心生成、后高效衍生”方式降低了计算开销，实现了检测精度与模型轻量化的协同优化，其结构如图 5 所示。




图 5 Ghost-ADown 结构图

Fig. 5 Diagram of Ghost-ADown structure

3.3 Detect-LSCD 检测头

为解决传统检测头在边缘计算平台部署时面临的资源受限问题，本文提出一种轻量级共享卷积检测头结构^[22]。该结构通过引入尺度感知的特征解耦机制、轻量化的特征增强模块，以及多模态特征融合策略，实现了高效、低延迟的目标检测性能。

LSCD 检测头采用双分支结构分别处理不同尺度目标。大目标分支侧重语义信息的提取以增强目标整体的语义表达，小目标分支则着重保留边缘细节以提升对目标检测能力。同时，为提

高特征选择针对性和高效性，LSCD 检测头引入通道注意力机制，特征增强环节通过融合深度分离卷积既可降低模型的计算成本，非对称卷积核又能提升模型的方向感知能力。此外，轻量化的 SE 注意力模块对通道维度进行加权处理，以有效加强模型对显著特征的响应能力。

在多尺度特征融合方面，LSCD 具有跨路径交互机制，其原理是将可学习的权重参数对不同分支的特征图进行加权融合，实现了信息的高效整合与重构，具体结构如图 6 所示。该模块由多个功能子模块构成：GN_Conv1×1 表示组归一




图 6 LSCD 检测头网络结构图

Fig. 6 Network structure diagram of LSCD detection head

化与 1×1 卷积的组合操作;GN_Conv 3×3 模块进行组归一化处理并共享权重;Conv_Reg模块负责位置回归预测,其权重在不同尺度之间共享;Conv_Cls模块采用权重共享策略用于目标分类,每个回归模块后均连接有一个缩放因子Scale模块,用于适配不同尺度下目标检测的需求。

通过上述结构优化,LSCD检测头在实现模型压缩和计算量压缩的同时有效地维持了检测精度,为边缘设备部署的实时目标检测任务提供了切实可行的技术路径。

3.4 Focaler-MPDIoU 损失函数

损失函数的核心功能是衡量模型预测结果与真实标签之间的差异程度,进而反映模型内部结构的变化趋势,为参数迭代更新提供优化方向。为提升检测性能,本文引入Focaler-IoU和MPDIoU,设计Focaler-MPDIoU损失函数替代原有模型的CIoU损失函数^[23],通过聚焦不同回归难度的样本,增强模型对关键样本的关注能力,即:

$$L_{\text{GIoU}} = 1 - \text{IoU} + \frac{|C - (A \cup B)|}{|C|}, \quad (3)$$

式中: A 为预测框; B 为真实框;IoU表示预测框与真实框的重叠损失; C 表示能够包围预测框 A 和真实框 B 的最小外接圆面积。

GIoU^[24]虽然一定程度上考虑到重叠部分,但当预测框与真实框完全相同时,GIoU会退化为IoU,限制了进一步优化的能力。为解决该问题,研究者相继提出了MPDIoU^[25]以及Focaler-IoU^[26]。MPDIoU利用几何信息以及多个点的距离进行衡量以提升回归准确率与鲁棒性,Focaler-IoU则是专注于解决难定位的问题而更好地服务于目标检测任务。

两个损失函数分别见式(4)和式(5):

$$\begin{cases} A_{\text{pre}} = (x_1^{\text{pre}}, y_1^{\text{pre}}, x_2^{\text{pre}}, y_2^{\text{pre}}) \\ A_{\text{gt}} = (x_1^{\text{gt}}, y_1^{\text{gt}}, x_2^{\text{gt}}, y_2^{\text{gt}}) \\ d_1^2 = (x_1^{\text{pre}} - x_1^{\text{gt}})^2 + (y_1^{\text{pre}} - y_1^{\text{gt}})^2 \\ d_2^2 = (x_2^{\text{pre}} - x_2^{\text{gt}})^2 + (y_2^{\text{pre}} - y_2^{\text{gt}})^2 \\ L_{\text{MPDIoU}} = 1 - \text{IoU} + \frac{d_1^2}{w^2 + h^2} + \frac{d_2^2}{w^2 + h^2} \end{cases}, \quad (4)$$

式中: A_{pre} 预测边界框的坐标, A_{gt} 为真实标注边界框的坐标, x_1, y_1 为框的左上角坐标, x_2, y_2 为框的右下角坐标; d_1^2, d_2^2 为预测边界框与真实标注边界框之间的左上角和右下角的距离, w, h 为图

片的宽度和高度。

$$L_{\text{Focaler-IoU}} = \begin{cases} 0, & \text{IoU} < d \\ \frac{\text{IoU} - d}{u - d}, & d \leq \text{IoU} \leq u \\ 1, & \text{IoU} > d \end{cases}, \quad (5)$$

式中:IoU为预测框与真实框的重叠损失, d 为目标区域的密度, u 为目标区域的预测置信度, $[d, u] \in [0, 1]$ 。

本文将Focaler-IoU与MPDIoU结合,并提出Focaler-MPDIoU损失函数,即:

$$L_{\text{Focaler-MPDIoU}} = L_{\text{MPDIoU}} + \text{IoU} - L_{\text{Focaler-IoU}}. \quad (6)$$

针对检测任务中正负样本分布不均匀的问题,Focaler-MPDIoU通过引入高阶特征信息与样本聚焦机制,有效缓解该问题。同时,Focaler-MPDIoU采用结合多尺度特征融合与动态权重分配的策略,进一步增强了样本定位的准确性与鲁棒性。相较于CIoU,Focaler-MPDIoU在多种复杂场景下均展现出更优的检测性能,尤其是在小目标检测与重叠目标识别等挑战性任务中。

4 数据集制作

本文所用到的数据集由两部分组成。一部分源自企业实地测试阶段采集的数据,图像采集设备为高速相机,分别在不同角度和天气下随机拍摄采集的907张锥筒图像;为确保实验结果的泛化性及不同条件下模型的鲁棒性,另一部分从公开数据集TarCon随机获取700张锥筒图像。其后,通过OpenCV对数据集图像进行缩放与填充处理,统一调整为 640×640 的像素尺寸,完成裁剪和归一化操作,并使用LabelImg工具对锥筒目标进行标注,保存为YOLO格式。

为提高训练模型的适应性和鲁棒性,使用Mosaic数据增强技术扩充原始图像数据集^[27],同时为避免测试集和训练集之间的重复与提高样本质量,采取先划分后增强的处理策略。锥筒图像随机按7:2:1的比例划分成训练集1055张、验证集301张和测试集151张,并对训练样本进行亮度调节、噪声、平移、翻转和镜像等图像数据处理,扩充后的图像共3108张。数据集涵盖了6种应用场景下的道路影像,即晴天、阴天、雨天、雾天、黑夜以及隧道。图7为不同环境下的锥筒样本。



图 7 锥筒样本图。(a)雾天;(b)隧道;(c)夜间;(d)雨天;(e)阴天;(f)晴天。

Fig. 7 Cone cylinder sample diagram. (a) Foggy day; (b) Tunnel; (c) Nighttime; (d) Rainy day; (e) Cloudy day; (f) Sunny day.

在实际应用场景中,锥筒易被车流遮挡、相互重叠,少量锥筒还出现表面脏污、老化、反光条脱落等现象,导致识别困难。为此,本文构建的数据集中专门包含了此类难识别样本,如图 8 所示。



图 8 困难识别锥筒样本

Fig. 8 Difficult-to-identify cone sample

5 实验结果分析

5.1 训练环境配置及训练参数

为保障实验顺利进行并获取到可靠结果,本实验在相同的配置下进行。实验配置如表 1 所示,实验参数设定如表 2 所示。

表 1 实验环境配置

Tab. 1 Experimental environment configuration	
Hardware configuration	Parameters
CPU	12th Inter(R)Core(TM)i5-12600KF
GPU	NVIDIA GeForce RTX 4060
CUDA	11.6
RAM	32 GB
Development environment	Pytorch1.13.1+Python3.8
Operating system	Windows 10

表 2 实验参数设置

Tab. 2 Experimental parameter settings

Experimental parameters	Parameter values
Initial LR	0.01
Epoch	200
Weight decay	0.0005
Batch size	16
Optimizer	SGD

5.2 性能评价指标

为评估模型性能,本文选取了目标检测任务中常用的指标:平均精度值(mean Average Precision, mAP)、模型参数量(Parameters)、浮点计算量(Floating Point of Operations, FLOPs)及模型存储体积(Model Size)。其中:mAP@50 表示交并比(IoU)阈值为 0.5 时的平均精度;参数量指模型中所有可训练参数的总个数;浮点运算量用于

反映模型的计算复杂度;模型存储体积则对应储存参数所需的磁盘空间^[28]。精度与召回率的计算公式如下:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\%, \quad (7)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\%, \quad (8)$$

$$\text{AP} = \int_0^1 P(r) dr, \quad (9)$$

$$\text{mAP} = \frac{\sum_{i=1}^n \text{AP}_i}{n}, \quad (10)$$

式中:TP(True Positive)为正确目标预测为正确目标的数量,FP(False Positive)为错误目标预测为正确目标的数量,FN(False Negative)为正确目标预测为错误目标的数量。

5.3 C3K2-RC 模块消融实验

为筛选出效果最佳的 C3K2 模块改进方案,分别使用 C3K2-RC 模块对主干网络(Backbone)、

头部网络(Head)和整体网络的 C3K2 模块进行替换,4 组实验的结果如表 3 所示。

由表 3 数据可知,在同时替换主干网络和头部网络的 C3K2 模块后,模型参数量相比其他两种方案分别降低了 0.14×10^6 和 0.18×10^6 ,模型存储体积均下降 0.4 MB;与原始 YOLOv11n 相比,该方案参数量和模型存储体积分别减少 0.41×10^6 和 0.8M,精确率提升 0.1%,召回率下降 0.9%,mAP@0.5 下降 0.8%。变化主要归因于 C3K2-RC 模块对传统卷积结构的替代与优化,该模块采用高效深度卷积的 CGLU 以及推理时融合的 RepConv,大幅减少了卷积核数量与计算量。RepConv 的 3 条支路带有的 BatchNorm 虽然增强了梯度流,但 BN 层的统计量在小批量或复杂场景下可能不稳定,导致推理时融合后的等效卷积产生偏差。综上,同时替换 Backbone 和 Head 在不牺牲过多精度的前提下实现了轻量化,是轻量化与精度平衡的最佳方案。

表 3 C3K2-RC 模块消融实验

Tab. 3 Ablation experiment of C3K2-RC module

Network structure	Params/ 10^6	Model size/MB	Precision/%	Recall/%	mAP@0.5/%
YOLOv11n	2.58	5.3	94.2	90.1	92.7
Backbone	2.31	4.9	94.5	88.7	92.5
Head	2.35	4.9	93.7	88.2	92.2
Backbone+Head	2.17	4.5	94.3	89.2	91.9

5.4 G-ADown 模块消融实验

为验证 G-ADown 模块在降低原模型参数量方面的效果,以及 G-ADown 模块分别在 Backbone、Head、Backbone+Head 中的性能,设计了 5 组消融实验,实验结果如表 4 所示。

由实验数据可知,G-ADown 模块同时集成在主干网络和颈部网络时,参数量与模型存储

体积比原始 YOLOv11n 分别减少 0.52×10^6 和 1.0 MB,精确率提升 0.6%、召回率提升 0.3%、平均精度均值提升 0.2%。同时,该模块融合 Ghost 卷积与自适应下采样策略,通过线性变换生成冗余特征图减少计算量,以及在 ADown 平均池化与最大池化并行处理方案中优化下采样路径,从而在降低参数冗余和结构复杂性的

表 4 G-ADown 模块消融实验

Tab. 4 Ablation experiment of G-ADown module

Network structure	Params/ 10^6	Model size/MB	Precision/%	Recall/%	mAP@0.5/%
YOLOv11n	2.58	5.3	94.2	90.1	92.7
ADown	2.18	4.8	95.2	91.3	93.2
Backbone	2.33	4.6	95.4	89.3	92.3
Head	2.20	4.5	94.6	89.4	91.4
Backbone+Head	2.06	4.3	94.8	90.4	92.9

同时,有效保留了特征图中的关键信息。因此,以结合开发高性能、轻量化的检测算法为目标,本研究选择将 G-ADown 模块同时集成在主干网络和颈部网络,最佳地平衡了检测精度与模型轻量化,不仅实现了比原始 YOLOv11n 更高的检测精度而且实现了计算效率更高的体系结构。

5.5 不同改进方法的消融实验

为进一步评估 C3K2-RC、G-ADown、Detect-LSCD 及 Focaler-MPDIoU 四种改进方法对模型性能的提升,本研究以 YOLOv11n 为基准模型(试验①)设计了 10 组消融实验,旨在评估各组件在复杂道路场景下对锥筒目标的独立作用与协同增强效果,实验结果如表 5 所示。

表 5 不同改进方法的消融实验结果

Tab. 5 Results of ablation experiment of different improved methods

Model	C3K2-RC	G-ADown	Detect-LSCD	Focaler-MPDIoU	Params/ × 10 ⁶	Model size/ MB	Precision/%	Recall%	mAP@0.5%
①	×	×	×	×	2.58	5.3	94.2	90.1	92.7
②	√	×	×	×	2.17	4.5	94.5	89.2	91.9
③	×	√	×	×	2.06	4.3	94.8	90.4	92.9
④	×	×	√	×	2.43	4.6	94.4	89.5	92.1
⑤	×	×	×	√	2.58	5.3	94.6	90.8	92.9
⑥	√	√	×	×	1.78	3.5	95.2	91.2	93.4
⑦	×	√	√	×	2.04	3.6	94.9	90.8	92.8
⑧	√	×	√	×	2.00	3.9	94.1	89.0	92.4
⑨	√	√	√	×	1.67	3.1	94.7	91.3	93.8
⑩	√	√	√	√	1.67	3.1	95.3	91.5	94.3

从表 5 数据可看出,替换不同的模块均能使模型的计算量以及参数量降低,但单个模块优化效果各有不同。C3K2-RC 模块可压缩模型存储体积,但单用时 BN 层的统计量在小批量或复杂场景下可能不稳定,导致推理时融合后的等效卷积产生偏差,造成漏检率升高。Ghost-ADown 模块具有良好的平衡性,表明 Ghost 卷积与自适应下采样的结合在降低计算量的同时,还能有效保留特征图中的关键信息,兼顾效率与精度。Detect-LSCD 检测头采用参数共享机制使检测层计算量减少,Focaler-MPDIoU 损失函数则可使模型更好地关注难以区分的目标,在不需要额外增加计算量情况下提高检测效果。

多模块实验中,C3K2-RC 与 Ghost-ADown 组合⑥表明,特征提取模块与下采样模块的互补关系可兼顾轻量化与检测效果。Ghost-ADown 与 Detect-LSCD 的组合⑦相比 YOLOv11n 参数量降低 0.54×10^6 ,但准确率、召回率及 mAP@0.5 均有所下降。因此,单纯追求下采样和检测头的轻

量化而缺乏特征增强机制,可能导致特征信息损失而降低检测效果。C3K2-RC 与 Detect-LSCD 组合⑧各项指标较基准模型均有提升,但召回率以及 mAP@0.5 低于组合⑥,说明检测头轻量化只有与对应的特征提取能力匹配才能有良好表现。C3K2-RC、Ghost-ADown 和 Detect-LSCD 组合⑨充分表征了模块在特征提取、下采样和检测头设计方面的协同效应。

全模块集成模型 RGLU-YOLOv11n⑩在组合⑨的基础上,进一步融入了 Focaler-MPDIoU 损失函数。参数量和模型存储体积相比基准模型降低了 35.3%、41.5%,模型准确率、召回率和平均精度分别提高了 1.1%、1.7% 和 1.4%。4 个模块的有机协同运行,在保证模型轻量化的同时,既显著提升了锥筒目标的检测性能,又能满足边缘设备部署低复杂度与检测高精度的双重需求。

5.6 不同损失函数对模型的影响

为了改善 CIoU 损失函数在检测时泛化性弱和收敛速度慢的问题,引入 Focaler-IoU 和 MPDIoU,

设计Focaler-MPDIoU损失函数替代原有模型的损失函数,以提高模型精度并加快边界框回归速度。为验证损失函数的有效性,将Focaler-MPDIoU与EIoU、SIoU、DIoU等主流损失函数进行对比实验,结果如表6所示。

表6 不同损失函数结果对比

Tab. 6 Comparison of the results of different loss functions

Loss	Precision/%	Recall/%	mAP@0.5/%
EIoU	92.3	89.3	91.9
SIoU	93.8	90.1	93.2
DIoU	94.7	88.0	92.1
ShapeIoU	94.2	87.9	92.9
Focaler-GIoU	94.1	90.9	92.7
Focaler-MPDIoU	95.3	91.5	94.3

由实验结果可知,Focaler-MPDIoU在所有指标上均优于其他损失函数,精度达到95.3%,召回率达到91.5%,mAP@0.5达到94.3%,较DIoU分别提升了0.6%、3.5%和2.2%,较SIoU分别提升了1.5%、1.4%和1.1%。综上,Focaler-MPDIoU通过兼顾焦点机制对难样本的动态调节与边界点距离的直接优化,避免了SIoU中复杂的多阈值设定问题,从而使模型更加稳定高效地训练。

5.7 不同模型的对比实验

为验证改进后的RGLU-YOLOv11模型对锥筒检测的有效性,选取Faster R-CNN、YOLOv5n、YOLOv8n、YOLOv10n等模型,在自建锥筒数据集上进行训练和测试,实验结果如表7所示。

表7 不同模型的性能对比

Tab. 7 Performance comparison of different models

Model	Params/ 10^6	GFLOPs/ 10^9	Model size/MB	Precision/%	Recall/%	mAP@0.5/%
Faster R-CNN	186.3	427.2	113.9	94.5	89.1	88.3
YOLOv5s	7.02	16.0	14.5	90.4	86.9	90.1
YOLOv8n	3.01	8.1	6.2	96.6	87.2	92.7
YOLOv10n	2.69	8.4	5.6	96.7	87.8	92.6
YOLOv11n	2.58	6.3	5.3	94.2	86.1	91.3
YOLOv12n	2.51	6.4	5.2	94.4	86.6	90.3
YOLOv13n	2.44	6.2	5.0	94.6	85.6	91.4
YOLOv26n	2.38	5.4	4.8	93.5	85.2	90.1
YOLOv13-Cone-Lite ^[29]	2.52	6.1	3.8	94.7	88.4	93.2
Ours	1.82	5.3	3.5	96.3	91.8	94.1

通过实验数据可知,与Faster R-CNN相比,RGLU-YOLOv11n算法在精确率、召回率和平均精度均值上分别提升1.8%、2.7%和5.8%,但模型存储体积仅为Faster R-CNN的3.07%,参数量仅为Faster R-CNN的0.98%,充分体现了算法在保持高检测精度的同时实现了极致的模型轻量化。相比YOLOv5s、YOLOv8n、YOLOv10n、YOLOv11n、YOLOv12n及YOLOv13n等轻量级网络,本文算法的参数量分别降低 5.20×10^6 、 1.19×10^6 、 0.87×10^6 、 0.76×10^6 、 0.69×10^6 和 0.62×10^6 ,模型存储体积分别降低11.0 MB、2.7 MB、2.1 MB、1.8 MB、1.7 MB、和1.5 MB,平均精度均值分别提高4.0%、1.4%、1.3%、

2.8%、3.8%和2.7%。本文改进后算法相较于YOLOv11n,参数量和模型存储体积分别降低 0.76×10^6 和1.8 MB,计算量减少 1.0×10^9 G,同时准确率、召回率、平均精度均值分别提高2.1%、5.7%和2.8%。

此外,本文还选取了长安大学某研究中面向封闭赛道自动驾驶场景的交通锥检测算法进行对比。实验结果显示,该算法在本文自制数据集上的各项检测指标均不如本文所提出的算法。

以上结果充分表明,与其他主流算法相比,本研究所提出的改进算法不仅模型体积小、参数量低、计算开销小,而且实现了更高的检测精度和准确率,更便于移植应用于锥筒实时目标检测

任务应用场景。

5.8 可视化效果对比实验

本文使用 RGLU-YOLOv11n 算法与 YOLOv11n 算法,分别在晴天、阴天、雨天、雾天、黑夜以及隧道共 6 种光线条件下,对锥筒目标进行

识别和检测,模型检测效果对比如图 9 所示。两种算法均能够完成对锥筒的识别,但当出现遮挡、密集分布,以及远距离小目标锥筒时,YOLOv11n 算法存在漏检现象;RGLU-YOLOv11n 算法检测则更完整准确且识别准确度更高。



图 9 模型检测效果对比
Fig. 9 Comparison of model detection results

5.9 泛化性能实验

为验证本文改进算法的泛化性,本文使用由东北大学宋克臣团队制作的 NEU-DET 钢材表面缺陷数据集,专注于钢材表面缺陷的检测与识别。NEU-DET 共包含 1 800 张图片,包括 6 种常见的钢材表面缺陷类型:裂纹(Crazing)、夹杂物(Inclusion)、斑点(Patches)、麻面(Pitted Surface)、轧入氧化皮(Rolled-in Scale)、划痕(Scratches),数据集按 8:1:1 划分为训练集、验证集和测试集,

实验参数和评价指标不变^[30]。
实验结果如表 8 所示,在 NEU-DET 数据集上,本文提出的优化模型在关键指标上均取得稳定提升。具体而言,优化后的模型将平均精度均值(mAP@0.5)提升至 77.4%,较 YOLOv11n 基线模型提高了 0.5%;同时,精确率与召回率分别达到 75.1% 和 74.2%,相比基线模型分别增长 4.8% 和 3.5%。这些数据充分说明,改进后的检测算法在钢材表面缺陷识别任务中具有更卓越

表 8 本文模型与 YOLOv11n 模型在 NEU-DET 数据集上的泛化实验结果对比

Tab. 8 Comparison of generalization experiment results between the proposed model and YOLOv11n on the 9NEU-DET data set

Model	Precision/%	Recall/%	mAP@0.5/%	Params/ 10^6	GFLOPs/ 10^9	Model size/MB
YOLOv11n	70.3	70.7	76.9	2.52	6.3	10.2
Ours	75.1	74.2	77.4	1.36	4.5	2.8




图 10 本文模型与 YOLOv11n 模型在 NEU-DET 数据集上的检测结果对比
Fig. 10 Comparison of detection results between the proposed model and YOLOv11n on the NEU-DET data set

的检测性能。此外,该模型在复杂度控制方面也表现优异,参数量、计算量以及模型存储体积分别降至 1.36×10^6 、 4.5×10^9 和2.8 MB,均显著低于基线模型。从图10的可视化结果可以看出,本文算法相比于基准模型能更准确地检测出缺陷目标,进一步验证了本文算法在检测任务中的优势。

5.10 模型部署实验

本研究基于Raspberry Pi 5(8GB版本)嵌入式平台,搭配具备夜视功能的200万像素摄像头,对改进后的锥筒检测算法进行部署,以验证其在移动端设备上的实际应用性能。选用该平台作为验证平台,旨在模拟资源受限的边缘计算极端场景^[31],以证明所提算法在极端条件下的适应性。硬件接线方式如图11所示。




图11 Raspberry Pi 5实物图

Fig. 11 Raspberry Pi 5 physical diagram

为实现模型的高效转换与部署,采用基于ONNX中间格式和NCNN框架的深度学习模型优化方案。NCNN是腾讯优图实验室开源的轻量级神经网络推理框架,采用纯C++实现且无第三方依赖,具有显著的轻量化优势。该框架通过深度优化ARM架构处理器(如树莓派)和支持多核处理器,有效地提升了推理速度。NCNN支持Linux、Android、iOS和Windows等多种操作系统并适配ARM、x86和MIPS等芯片架构,为不同硬件环境下的模型部署提供了灵活性,且能够

处理来自ONNX、PyTorch、TensorFlow、Caffe等主流深度学习框架的模型,其内置的卷积、LSTM和注意力机制等常用算子,覆盖了大多数神经网络结构的需求。NCNN还提供INT8、FP16和FP32多级量化方案,通过降低可接受范围内的计算精度来显著提升推理速度。相较于FP32模型,FP16模型的推理速度提升了2~3倍,模型体积减小50%,能够有效降低GPU运行压力,且精度损失优于INT8量化方案,更适合部署于树莓派5平台。

YOLOv11n模型经NCNN格式部署在树莓派5的实时检测帧率为7.2帧/s,检测精度约为80%;而RGLU-YOLOv8n模型在相同部署方式下的实时检测帧率约为25.2帧/s,检测精度约为85%。相较于原始模型,改进后模型的帧率提升了2.5倍。在训练数据集的设备上进行检测,YOLOv11n模型检测帧率约为115帧/s,改进后的算法约为273帧/s,提升1.37倍。实验结果表明,改进后的算法在保持较小模型体积的前提下实现了较高的检测精度,具备更低的计算成本与高检测效率,更便于在移动设备上进行模型移植与部署。

6 结 论

针对锥筒检测精度与模型轻量化难以兼顾的问题,本研究提出一种轻量化高精度模型RGLU-YOLOv11n。该模型通过重参数化高聚合模块、幽灵下采样模块、轻量化共享卷积检测头,以及Focaler-MPDIoU损失函数的协同运行,在保持检测精度的同时显著降低模型的参数量与计算开销。经过实验,得出以下结论:

(1) 基于YOLOv11n进行改进,通过设计C3K2-RC重参数化高聚合模块,重构原始C3K2模块,显著降低模型在复杂环境下的计算量;引入Ghost卷积与ADown自适应下采样相结合,设计G-ADown轻量化下采样模块,在保持特征丰富度的同时有效降低下采样过程中的计算冗余;采用具有共享卷积机制的Detect-LSCD轻量化检测头,一定程度上减少模型的参数量,使模型更适于移植在资源受限的移动设备。此外,针对CIoU损失函数泛化性弱和收敛速度慢的问题,引入Focaler-IoU和MPDIoU,设计Focaler-MPDIoU

损失函数,在保持参数量不增加的情况下,提升模型的精度和加快边界框回归的速度。

(2)消融和对比实验证明,改进后的方法相比之前的模型,在减少模型参数量以及模型体积的情况下,检测效果有一定程度提高。在锥筒检测中,平均精度均值(mAP@0.5)为94.1%,召回率为91.8%,准确率为96.3%,参数量为 1.82×10^6 ,模型存储体积为3.5 MB,比基准模型YOLOv11n精确率、召回率、平均精度均值分别增加1.1%、1.4%和1.6%,参数量和模型存储体积分别减少35.3%和41.5%。由此可见,本文所提算法在检

测精度与模型轻量化之间取得了更优的平衡,能够满足移动端和嵌入式设备的实时检测部署需求,为锥筒检测提供了理论参考与实践方案。

(3)本文算法仍存在一定的局限性。锥筒收放机工作时是移动的,本文算法还未开展移动锥筒的检测实验。后续研究将考虑针对移动过程中对锥筒检测进行改进,同时通过图像增强技术改善输入图像质量,并收集更多复杂工况下的锥筒图像数据以丰富数据集的多样性,为锥筒自动收集的工业自动化检测提供更高效的支持。

参 考 文 献:

- [1] 张轩铭. 高速公路交通机电监控技术应用研究[J]. 运输经理世界, 2025(32): 141-143.
ZHANG X M. Research on the application of highway traffic electromechanical monitoring technology [J]. *Transport Manager World*, 2025(32): 141-143. (in Chinese)
- [2] 张政, 孙鹏, 王立勇, 等. 基于边缘卷积的交通锥筒点云数据分割方法[J]. 电子测量技术, 2023, 46(20): 98-103.
ZHANG Z, SUN P, WANG L Y, *et al.* Segmentation method via point cloud of traffic cones based on edge convolution [J]. *Electronic Measurement Technology*, 2023, 46(20): 98-103. (in Chinese)
- [3] 吴泽东. 基于机器视觉的交通锥筒自动收放机的研究[D]. 汉中: 陕西理工大学, 2024.
WU Z D. Research on automatic traffic cone recorder based on machine vision [D]. Hanzhong: Shaanxi University of Technology, 2024. (in Chinese)
- [4] 杨彬彬, 高中强. 基于YOLOv8的智能视频监控目标识别系统设计[J]. 电脑编程技巧与维护, 2026(2): 128-130.
YANG B B, GAO Z Q. Design of intelligent video surveillance target recognition system based on YOLOv8 [J]. *Computer Programming Skills & Maintenance*, 2026(2): 128-130. (in Chinese)
- [5] 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). Las Vegas: IEEE, 2016: 779-788.
- [6] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J/OL]. *arXiv*, 2018: 1804.02767.
- [7] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [J/OL]. *arXiv*, 2020: 2004.10934.
- [8] JOCHER G. YOLOv5 [EB/OL]. (2020-06-19)[2023-12-01]. <https://github.com/ultralytics/yolov5>.
- [9] LI C Y, LI L L, JIANG H L, *et al.* YOLOv6: a single-stage object detection framework for industrial applications [J/OL]. *arXiv*, 2022: 2209.02976.
- [10] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//*Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023: 7464-7475.
- [11] 刘博文, 徐卫平, 徐钦, 等. 基于改进YOLOX的猕猴桃分类识别与空间定位[J]. 国外电子测量技术, 2024, 43(4): 133-142.
LIU B W, XU W P, WU Q, *et al.* Classification identification and spatial localization of kiwifruit based on the improved YOLOX [J]. *Foreign Electronic Measurement Technology*, 2024, 43(4): 133-142. (in Chinese)
- [12] 吴泽东, 王明武, 韩继科, 等. 小型交通锥筒自动收放机设计与研究[J]. 陕西理工大学学报(自然科学版), 2023, 39(6): 24-31.

- WU Z D, WANG M W, HAN J K, *et al.* Design and research of small traffic cone automatic receiver [J]. *Journal of Shaanxi University of Technology (Natural Science Edition)*, 2023, 39(6): 24-31. (in Chinese)
- [13] SU Q H, WANG H D, XIE M, *et al.* Real-time traffic cone detection for autonomous driving based on YOLOv4 [J]. *IET Intelligent Transport Systems*, 2022, 16(10): 1380-1390.
- [14] 李旭,李刚,李永明,等. 轻量化的YOLOv8锥桶检测算法研究[J]. 重庆理工大学学报(自然科学),2024,38(7): 71-77.
- LI X, LI G, LI Y M, *et al.* Research on lightweight YOLOv8 cone bucket detection algorithm [J]. *Journal of Chongqing University of Technology (Natural Science)*, 2024, 38(7): 71-77. (in Chinese)
- [15] KATSAMENIS I, KAROULOU E E, DAVRADOU A, *et al.* TraCon: a novel dataset for real-time traffic cones detection using deep learning [C]//*Novel & Intelligent Digital Systems: Proceedings of the 2nd International Conference*. Cham: Springer, 2022: 382-391.
- [16] 李春晖,吕岩,孟祥来,等. 基于YOLOv8的油气管道漏磁检测缺陷智能识别技术研究[J]. 仪器仪表学报,2025, 46(2):247-254.
- LI C H, LYU Y, MENG X L, *et al.* Research on intelligent defect recognition in oil and gas pipeline magnetic flux leakage detection based on YOLOv8 [J]. *Chinese Journal of Scientific Instrument*, 2025, 46(2): 247-254. (in Chinese)
- [17] HUANG J L, YAO S W, WANG J Y, *et al.* Intelligent identification of mines and tailings pond based on the improved YOLOv8 model [J]. *Science of Surveying and Mapping*, 2025, 50(7): 70-82. (in Chinese)
- [18] SHI D. TransNeXt: robust foveal visual perception for vision transformers [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2023: 17773-17783.
- [19] 刘兆龙,曹伟,高军伟. 基于改进YOLOv7的小目标焊点缺陷检测算法[J]. 液晶与显示,2024,39(10):1332-1340.
- LIU Z L, CAO W, GAO J W. Defect detection of small object solder joints based on improved YOLOv7 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(10): 1332-1340. (in Chinese)
- [20] 蔡忠祺,林珊玲,林坚普,等. 基于改进YOLOv8n-Pose的疲劳驾驶检测[J]. 液晶与显示,2025,40(4):617-629.
- CAI Z Q, LIN S L, LIN J P, *et al.* Fatigue driving detection based on improved YOLOv8n-Pose [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(4): 617-629. (in Chinese)
- [21] WANG C Y, YE H I, LIAO H Y M. YOLOv9: learning what you want to learn using programmable gradient information [C]. 18th European Conference on Computer Vision. Milan: Springer, 2024: 1-21
- [22] SHEN Q, ZHANG L, ZHANG Y X, *et al.* Distracted driving behavior detection algorithm based on lightweight StarDL-YOLO [J]. *Electronics*, 2024, 13(16): 3216.
- [23] LI J W, LIU S T, CHEN D, *et al.* APD-YOLOv7: enhancing sustainable farming through precise identification of agricultural pests and diseases using a novel diagonal difference ratio IOU loss [J]. *Sustainability*, 2024, 16(20): 8855.
- [24] REZATOFIGHI H, TSOI N, GWAK J, *et al.* Generalized intersection over union: a metric and a loss for bounding box regression [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach: IEEE, 2019: 658-666.
- [25] MA S L, XU Y. MPDIoU: a loss for efficient and accurate bounding box regression [J/OL]. *arXiv*, 2023: 2307.07662.
- [26] ZHANG H, ZHANG S J. Focaler-IoU: more focused intersection over union loss [J/OL]. *arXiv*, 2024: 2401.10525.
- [27] JALALI B, MACPHEE C. VEVid: vision enhancement via virtual diffraction and coherent detection [J]. *eLight*, 2022, 2: 24.
- [28] 刘彦磊,李孟喆,王宣宣. 轻量型YOLOv5s车载红外图像目标检测[J]. 中国光学(中英文),2023,16(5):1045-1055.
- LIU Y L, LI M Z, WANG X X. Lightweight YOLOv5s vehicle infrared image target detection [J]. *Chinese*

- Optics*, 2023, 16(5): 1045-1055. (in Chinese)
- [29] WANG Z K, HU S H, WANG X T, *et al.* YOLOv13-cone-lite: an enhanced algorithm for traffic cone detection in autonomous formula racing cars [J]. *Applied Sciences*, 2025, 15(17): 9501.
- [30] 陈名渝, 谢珉辰, 吕雄涛, 等. 冷轧钢表面与内部缺陷检测研究[J]. 中国光学(中英文), 2024, 17(4): 823-833.
CHEN M Y, XIE Y C, LV X T, *et al.* Detection of surface and internal defects in cold rolled steel [J]. *Chinese Optics*, 2024, 17(4): 823-833. (in Chinese)
- [31] LIANG Y H, WANG J, XUE K W, *et al.* High-clockrate free-space optical in-memory computing [J]. *Light: Science & Applications*, 2026, 15: 115.

作者简介:



李 奥,男,硕士研究生,2019 年于安阳学院获得学士学位,主要从事先进制造技术及装备方面的研究。E-mail: 2509260778@qq.com



王明武,男,硕士,副教授,2007 年于郑州轻工业大学获得硕士学位,主要从事先进工业自动化技术集成与应用方面的研究。E-mail: wangmingwu@163.com