

基于轻量化 YOLOv11n 炮孔红外图像检测模型研究^{*}李亮川¹ 郭龙谊² 孙 猛¹ 张小栋² 钟 山²

(1. 中铁二十局集团有限公司 西安 710016; 2. 西安交通大学机械工程学院 西安 710049)

摘 要: 针对隧道炮孔识别中因光照不足、粉尘浓度大导致的精度低、模型权重高等问题,提出了一种结合红外热成像与深度学习技术的轻量级炮孔检测模型。以 YOLOv11n 为基线模型,首先集成轻量级 StarNet 网络,增强多尺度特征提取能力并优化计算效率;其次引入 Star Block 模块,构建 C3k2_BlockStar 模块,提升不同尺度特征融合效果;最后设计轻量化检测头,进一步降低计算复杂度。实验表明,改进后模型参数量减少 54%,模型大小缩减 32%,能有效识别隧道红外炮孔,为隧道施工中机器人自动化装药提供了技术基础,具有较高的实用价值和应用前景。

关键词: 炮孔检测;红外图像;YOLOv11;轻量化模型

中图分类号: TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Research on a lightweight YOLOv11n-based detection model for
blast hole infrared imagesLi Liangchuan¹ Guo Longyi² Sun Meng¹ Zhang Xiaodong² Zhong Shan²

(1. China Railway 20th Bureau Group Co., Ltd., Xi'an 710016, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the challenges of low accuracy and high model complexity in tunnel blast hole recognition caused by poor lighting and high dust levels, this study proposes a lightweight blast hole detection algorithm that integrates infrared thermal imaging with deep learning technology. Using YOLOv11n as the baseline model, the lightweight StarNet network is first incorporated to enhance multi-scale feature extraction capabilities and optimize computational efficiency. Subsequently, the Star Block module is introduced to construct the C3k2_BlockStar module, improving the fusion of features at different scales. Finally, a lightweight detection head is designed to further reduce computational complexity. Experimental results demonstrate that the improved model reduces the number of parameters by 54% and the model size to 32% of the original, achieving effective recognition of tunnel infrared blast holes. This research provides a technical foundation for robotic automated charging in tunnel construction, offering significant practical value and application prospects.

Keywords: blast hole detection; infrared images; YOLOv11; lightweight model

0 引 言

目前铁路、公路及地铁等隧道工程的施工开挖方式以钻孔爆破法^[1]为主,其主要包括钻孔、装药、连线、起爆 4 个步骤。而在钻爆法施工的一系列步骤中,精准装药是决定爆破效果的关键环节,也是当前面临的主要技术难题之一。传统依靠人工进行装药的方法不仅效率低、存在安全风险^[2],而且难以满足当下对智能化装药的需求。因此,研发具备炮孔精准识别的智能化装药机器人^[3],实现自动化作业,对于降低施工成本、提高掘进作业效率及保障作业安全

性均具有重要意义。精准的炮孔检测和定位算法是智能化装药控制系统的核心所在,对于实现钻爆法施工的装药自动化方面具有重要的意义。

随着人工智能技术的飞速发展,基于深度学习的检测方法通过先进的图像处理技术,实现隧道掌子面炮孔快速精准识别。刘权等^[4]以 YOLOv7 为算法基础,引入无参注意力模块(simple attention module, SimAm)和更换损失函数(enhanced intersection over union loss, EIou)优化了炮孔特征识别网络,对低下矿中的炮孔图像有着良好的识别效果。胡启国等^[5]针对由于炮孔形状各异、背景复杂导

致的误检和漏检等问题,提出了一种更高效的炮孔检测方法,通过跨空间学习模块将信息进行融合,提升模型的感受野和表征能力,从而提高炮孔的检测精度。岳中文等^[6]为解决隧道掘进作业环境炮孔检测和实时性部署问题,采用了具有动态非单调聚焦机制的损失函数 WIoU (wise intersection over union) 优化边框回归的损失,同时将 MobileNetv3-Small 网络与 CBAM (convolutional block attention module) 注意力机制构建了主干网络,以减少模型参数,从而满足轻量化的部署需求。Zhang 等^[7]提出了一种改进的 Faster R-CNN 网络用于炮孔检测与炮孔数量和间距的自动采集,显著提高了掌子面整体炮孔参数智能获取的能力。Pan 等^[8]针对背景岩石的多样性和不均匀的光照强度,提出了一种级联网络用于炮孔检测,结果表明该方法增强了图像的对比度,实时提高了炮孔检测的准确性。张兴长等^[9]拍摄现场图片自制炮孔数据集,对比了 Faster R-CNN 和 YOLOv5 在数据集上各项性能的优劣,得出结论 YOLOv5 检测速度快,权重文件小,更适用于实际工程场景。胥维等^[10]提出了基于三维点云和基于目标检测的两种炮孔智能识别方法,通过多源视觉感知设备,在多个露天矿山环境下进行试验验证,详细比较了两种方法的处理流程和应用潜力。金庆雨等^[11]提出了炮孔智能化检测和路径规划系统,该系统在炮孔检测方面的准确率可达 96.24%。

尽管深度学习技术已经在炮孔识别领域已取得一定进展,但是现有的研究仅局限于基于可见光图像的检测方法,然而隧道环境中常存在光照不足、粉尘干扰等问题,严重影响检测性能。近年来,红外图像在低照度、高噪声环境下的目标检测中展现出巨大潜力。在无人机对地观测中,融合可见光与红外图像能有效提升复杂场景下的目标识别能力^[12]。在工业检测领域,基于改进 EfficientNet 等轻量化网络的红外图像分析,已被成功应用于光伏组件故障识别等任务,在保证精度的同时显著降低了模型复杂度^[13]。特别地,针对红外图像中小目标检测的难题,研究者通过设计多尺度感知模块^[14]、引入注意力机制增强特征^[15]、多尺度配准与融合红外与可见光图像^[16]等策略,有效提升了模型的鲁棒性与精度。这些工作表明,将红外成像与先进的轻量化深度学习模型相结合,是解决恶劣环境下目标检测问题的有效途径。然而,这一技术路径应用于隧道炮孔检测的研究尚属空白。现有方法未能充分利用红外图像在低照度、高粉尘隧道环境下的成像优势。

从应用层面来看,炮孔检测的最终目标是实现自动化装药,而装药设备受限于嵌入式处理器的计算资源,其计算能力难以满足现有目标检测算法的需求。因此,开发一种兼具轻量化、低计算复杂度与高识别性能的隧道炮孔检测模型已成为该领域亟待解决的关键问题。

针对上述问题,本文创新性地选用红外热成像作为数据源,并基于 YOLOv11n 模型进行优化改进,提出了一种

基于红外图像的轻量化 YOLOv11n 炮孔检测模型。该模型可满足边缘部署的要求,能够实现装药机器人在自动化装药任务中的高效目标检测。通过改进 YOLOv11n 模型,提高检测精度,降低误检率和漏检率,同时降低模型的计算量和权重,以适应装药设备有限的计算资源。

1 YOLOv11n 模型及其改进

1.1 YOLOv11n 模型概述

如图 1 所示,YOLOv11n 模型架构可划分为 4 个核心模块:输入层、骨干网络、特征融合网络以及检测头。




图 1 YOLOv11n 网络结构

Fig. 1 YOLOv11n network structure

输入层将输入的图像数据调整并统一,其尺寸大小为 640×640 pixels。骨干网络基于 CSPDarknet53 改进而成,对输入的图像进行特征提取。在骨干网络中,YOLOv11n 首先采用卷积与归一化对输入特征图进行变换,并借助 SiLU 激活函数实现非线性映射,从而提升特征表征能力;为进一步优化特征提取,该网络引入 C3k2 (cross stage partial with kernel size 2) 模块,该结构通过并行卷积层分支实现多尺度特征融合,提升了模型的特征学习效率与表征精度;SPFF (spatial pyramid pooling fast) 模块通过多尺度池化操作将可变尺寸的特征图统一转换为固定维度的表征,这种分层池化策略显著增强了特征空间的多样性;C2PSA (cross stage partial with pyramid squeeze attention) 模块通过改进的 PSA 机制优化了特征提取过程,在传统 SE (squeeze-and-excitation) 注意力基础上引入多层次空间建模,从而提升多层次特征的表征能力。颈部网络采用了特征金字塔网络 (feature pyramid network, FPN) + 路径聚

合网络(path aggregation network, PAN)结构进行多尺度特征融合,其自底向上路径融合浅层位置细节与深层语义信息,有效提升目标定位精度。检测头采用解耦结构设计,针对不同任务特性,分类分支采用二元交叉熵损失,而定位分支则联合使用分布焦点损失(distribution focal loss, DFL)和完全交并比(complete intersection over union, CIoU)损失进行优化。此外分类检测头引入双重深度可分离卷积,有效减少了模型参数量与计算复杂度。YOLOv11n 在精度和速度上较前代 YOLO 均有显著提升。

1.2 用于隧道炮孔检测的网络结构改进

在隧道低照度及高尘雾的复杂环境下,对于炮孔的实时检测需要一个性能优越、识别迅速且精度高的检测模型。YOLOv11n 网络作为一种单阶段目标检测算法,以其卓越的识别精度与快速的检测性能在该领域展现了显著优势。然而,受隧道环境中光照不足及尘雾干扰等因素的影响,该模型在炮孔检测任务中的误检率与漏检率仍存在一定的局限性。因此,针对低照度与高噪声环境下的目标检测问题,

YOLOv11n 网络在模型优化与性能提升方面仍具有进一步的研究潜力与改进空间。

在真实隧道环境的影响下,炮孔的识别精度往往会受到影响,导致误检和漏检问题频发。为了解决这一问题,本文提出了一种基于红外图像的轻量化改进 YOLOv11n 模型,专门用于隧道环境下炮孔的检测,如图 2 所示。首先,针对检测模型速度慢、模型大,难以部署嵌入式模块的问题,将 YOLOv11n 原有的主干网络替换成轻量级的 StarNet 网络结构,StarNet 通过 element-wise 乘法操作实现高维和非线性的空间映射,以提高网络的性能,同时,引入 StarNet 的 Star Block 在颈部网络中构建一个轻量级的特征提取模块 C3k2_BlockStar,提高模型对炮孔多尺度特征的融合效果。此外,设计轻量化炮孔检测头(lightweight tunnel blasthole detection head, LTBD-Head),进一步降低模型的大小和计算需求。上述改进旨在确保模型对隧道炮孔保持高性能检测的同时,进一步降低其计算复杂度,实现模型轻量化。




图 2 改进后总体网络结构
Fig. 2 Improved overall network structure

1.3 StarNet 轻量化网络

为了进一步提高模型在炮孔检测任务中的性能,降低模型的复杂度,本文使用 StarNet^[17]代替原来的主干网络。StarNet 的设计简洁高效,能够在不增加复杂性和过多超参数调节的情况下,保持卓越的性能。该网络通过多个堆叠的 Star 模块(由 element-wise 乘法操作连接的两条线性变换分支)来提取特征,在每一层中不显著增加计算复杂度,同时实现了高维度的隐式特征表示。

StarNet 网络结构如图 3 所示,其核心在于 element-wise 乘法操作(star 运算),通过将输入特征映射到一个高维空间来增强模型的表示能力。具体而言,假设输入特征为:

$$\mathbf{x} = \begin{bmatrix} \mathbf{X} \\ 1 \end{bmatrix} \quad (1)$$

其中, $\mathbf{x} \in \mathbf{R}^{d+1}$ 为高维特征向量, d 为特征维度。




图 3 StarNet 网络结构
Fig. 3 The network structure of StarNet

网络的权重矩阵 $\mathbf{W}$ 和偏置 $\mathbf{B}$ 可以表示为:

$$w = \begin{bmatrix} W \\ B \end{bmatrix} \quad (2)$$

在每一层中,star 操作通过 element-wise 乘法将两组线性变换的结果结合起来,计算公式为:

$$(W_1 X + B_1) * (W_2 X + B_2) \quad (3)$$

该操作使得网络能够在不显著增加计算复杂度的情况下,扩展特征维度,实现对高维非线性特征的有效建模。

对基于红外图像的隧道炮孔检测,StarNet 可以能够高效地处理红外炮孔图像中的复杂特征,特别是在低对比度和目标细节模糊的情况下,StarNet 通过 star 运算将输入特征映射到一个高维空间,捕捉到更为精细的特征,进而提升了隧道炮孔的检测能力。

1.4 C3k2_BlockStar 模块

C3k2 模块是 Neck 网络的重要组成部分,其设计旨在通过特征变换、分支和融合等操作来提取和转换输入特征,生成更具代表性的输出。C3k2 模块采用了通道分离策略和特征拼接机制,将输入特征分为两部分:一部分直接传递;另一部分通过深度特征提取模块(如 C3k 或 Bottleneck)处理。通过沿着通道维度的不同分支特征级联,促进模块内的特征融合,从而丰富了上下文信息并增强了模型的特征表示能力。这种设计在保持轻量化的同时,显著提升了计算效率,减少了计算负载。

为了进一步降低计算复杂度和提高效率,本文引入 Star Block 模块,设计一种新的 C3k2 变体 C3k2_BlockStar 模块。该方法利用星操作的高计算效率来提高 C3k2 模块内的特征提取能力,重新设计的 C3k2_BlockStar 模块结构如图 4 所示。




图 4 C3k2_BlockStar 结构

Fig. 4 C3k2_BlockStar structure

在 Star Block 中,传统的 3×3 卷积核被深度可分卷积和逐点卷积所取代,在保持计算效率的同时,增强了模型对局部特征的捕获能力。同时 Star Block 中的双分支设计实现不同特征通道的交互。两个分支以同样的方式通过 1×1 的卷积将输入维度进行扩展,而后通过 star 运算融合两路特征,有限提升了模型的表示能力,最后通过 ReLU6 激活函数,进一步提升了模型的非线性表达能力,防止梯度消失。与原 C3k2 模型相比,C3k2_BlockStar 进一步加深了网络,提高了对复杂场景中的细节特征捕获能力。

由于隧道环境中光线复杂、炮孔边缘特征往往模糊且形状不规则。C3k2_BlockStar 在增强局部特征提取和跨通道信息融合方面的改进,使得模型在检测隧道炮孔时更具鲁棒性。

1.5 轻量化炮孔检测头

检测头通常将网络的特征映射转换为目标检测框及位置信息和类别置信度信息。在 YOLOv11n 中,检测头同 YOLOv8 一样采用了解耦头结构,就算 YOLOv11n 使用了深度可分离卷积代替了部分常规卷积,YOLOv11n 共有 6 个 3×3 深度可分离卷积、6 个 3×3 常规卷积和 12 个 1×1 常规卷积,造成了 YOLOv11n 检测头的参数量过大。为了解决这一问题,本文优化了检测头的设计,在保持模型在复杂场景中准确定位和识别目标的前提下,减少模型的计算量、提升检测的速度和改善模型的运行效率,使其能够更好地满足实时性要求和高吞吐量场景的应用需求。

如图 5 所示,LTBD-Head 是一个基于特征金字塔网络的多尺度检测头结构。输入特征层为 P3、P4 和 P5,分别来自于不同尺度的特征图。每个输入特征图首先经过一个 3×3 的卷积(Conv_GN 3×3),用于调整通道维度和特征表示。之后,融合后的特征通过两个连续的 1×1 卷积(Conv_GN 1×1),进一步提取局部特征并保持空间信息。紧接着,这些共享特征分别输入到两个不同的分支:一个用于回归(Conv_Reg),输出边界框回归参数;另一个用于分类(Conv_Cls),输出类别置信度。最后巧妙地在回归分支引入 Scale 层进行特征缩放,对不同特征层的回归结果进行尺度校正。通过 Scale 层的调整,该模型能够实现不同尺度下特征的精确检测,从而进一步提高模型对不同尺寸目标的适应性和鲁棒性。




图 5 LTBD-Head 结构

Fig. 5 Structure of LTBD-Head

2 试验与分析

2.1 数据采集与预处理

本文依托眉太高速公路衙岭隧道工程,在不影响正常钻孔作业的前提下,采用飞础科 FOTRIC 628C 热成像仪采集了

多工况下的隧道炮孔图像数据,如图 6 所示。该热成像仪的核心参数经原厂标定,关键性能指标如表 1 所示,响应波段覆盖 7.5~14 μm 的长波红外波段,具备较强穿透性,可有效避

免隧道内尘雾干扰,640×480 pixels 像素分辨率及 30 Hz 帧率能保证炮孔细节的高保真采集,±2% 的测温精度可清晰区分炮孔与周围围岩的热辐射差异,满足检测需求。




图 6 不同工况下的红外炮孔图片

Fig. 6 Infrared images of blast holes under different working conditions

表 1 FOTRIC 628C 红外热成像仪技术参数
Table 1 Technical specifications of the FOTRIC 628C infrared thermal imager

关键参数	具体指标
红外分辨率	640×480 pixels
探测波长	7.5~14 μm
热灵敏度	<30 mK
帧率	30 Hz(视频流)
测温范围	-20℃~650℃
测温精度	±2℃或±2%(取最大值)
镜头焦距	25 mm
视场角	25°×18.7°
最小成像距离	0.3 m
空间分辨率	0.68 mrad

本实验选用-20℃~650℃量程,测温参数设置发射率为 1、反射温度为 20℃、红外窗口温度为 20℃、红外窗口透过率为 1,确保成像效果;镜头配置为标准镜头,焦距 25 mm,视场角 25°×18.7°,空间分辨率 0.68 mrad,最小成像距离 0.3 m,采集过程中控制拍摄距离为 1~2 m,确保单炮孔在图像中的像素尺寸满足模型特征提取需求。

利用 labelImg 工具完成对原始炮孔红外图像的标注工作,类别为 rhole,考虑到红外图像易受到设备抖动以及温度变化引起的干扰,为提高模型在复杂工况下的鲁棒性并抑制过拟合,对采集到的原始图像进行数据增强,具体操作如下:

- 1)随机旋转:随机旋转角度范围 $\theta \in [-30^\circ, 30^\circ]$,以模拟拍摄角度倾斜。
- 2)随机噪声注入:添加高斯噪声,均值 $\mu = 0$,方差 $\sigma^2 = 0.005$,以模拟红外传感器在低信噪比环境下的成像特征。
- 3)随机亮度调整:进行随机亮度调整,调整因子为 $\delta \in$

- [0.8, 1.2], 以适应不同时间段的温差成像变化。
 - 4)模糊处理:使用卷积核为 3×3 的高斯模糊来模拟对焦不准或粉尘导致的图像模糊。
- 经过上述的处理后,获得 800 张高质量红外炮孔图像。最终,将数据集按 7:2:1 的比例随机划分为训练集、验证集和测试集,以供模型训练与评估。

2.2 试验环境

本试验运行环境采用 Ubuntu 20.04 操作系统,处理器为 Intel(R) Core(TM) i7-11800H 2.3 GHz,显卡驱动为 RTX 3060 显卡。并行计算架构为 Cuda 12.1,编程使用 Python 3.9,基于 PyTorch 深度学习框架实现。

2.3 评价指标

为了评估模型的复杂性,本文选用参数数量和浮点运算次数(GFLOPs)作为衡量空间复杂度和时间复杂度的指标。评价算法性能方面,采用平均精度(average precision, AP)、平均类别精度(mean average precision, mAP)、精确率(precision, P)与召回率(recall, R)作为评估本文算法性能的主要标准。这些指标可以全面地衡量模型在空间和时间上的复杂度,以及算法在目标检测任务上的性能表现。各指标的计算公式如式(4)~(7)所示。

$$AP = \int_0^1 P(R) dR \tag{4}$$

$$mAP = \frac{1}{n} \sum_1^n AP_i \tag{5}$$

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$

式中:TP 为真实的正样本数量;FP 为虚假的正样本数量;FN 为虚假的负样本数量;AP 代表 PR 曲线以下的面积;mAP 为所有类别的平均 AP 值;n 表示本数据集的检测类别。

2.4 训练过程

在实验中,输入图像的尺寸固定在 640×640 pixels,模

型训练时每批次处理 32 张图像,共进行 300 个训练周期。采用随机梯度下降法(stochastic gradient descent, SGD)作为模型的参数优化算法,并使用余弦退火算法对学习率进行动态衰减。

改进模型的训练损失情况如图 7 所示。在前 100 个训练周期内,训练集与验证集的损失值均快速下降;100 个训练周期后,损失曲线逐渐收敛并趋于稳定,该趋势表明模型的训练过程有效,网络参数得到充分优化。




图 7 训练损失曲线

Fig. 7 Curve of training loss

2.5 消融试验

为系统验证本文所提出的各个改进模块对模型性能的贡献,本研究设计了一系列的消融实验。实验在第 2.1 节所述的自建隧道红外炮孔数据集上进行,该数据集包含 800 张标注图像,并按 7:2:1 的比例划分训练集、验证集和测试集。所有实验均保持统一的训练设置:输入图像尺寸为 640×640 pixels,批量大小为 32,采用 SGD 优化器,训练 300 个周期,并使用余弦退火策略调整学习率。实验目的在于,通过逐步引入 StarNet 主干替换(a)、C3k2_BlockStar 模块(b)和 LTBD-Head 检测头(c)这个 3 个关键的改进点,定量评估每个模块在模型轻量化和检测性能两方面的影响,并探究其组合效果。

如表 2 所示,共设计了 8 组对照试验:试验 1 作为基准模型,即原始的 YOLOv11n,未作任何改进;试验 2、3、4 则分别单独引入改进模块 a、b、c,旨在观察每个模块的独立作用;试验 5、6、7 为两两组合引入改进模块的试验(a+b, a+c, b+c),用于分析模块间的协同或互补作用;试验 8 作为同时引入全部 3 个改进模块(a+b+c)的最终模型,即本文提出的完整方案。

通过这些对比试验结果,清晰揭示每个改进模块对降低模型复杂度与维持或提升检测精度的具体贡献,从而论证本文模型改进策略的有效性。

表 2 消融试验对比

Table 2 Comparison of ablation experiments

试验	a	b	c	mAP/ %	P/ %	R/ %	参数量/ (×10 ⁶)	模型大小/ MB
试验 1	—	—	—	99.1	97.1	97.4	9.85	5.23
试验 2	✓	—	—	99.2	97.6	95.6	7.41	4.00
试验 3	—	✓	—	98.9	97.3	96.8	9.68	5.05
试验 4	—	—	✓	99.2	97.7	96.4	9.23	4.89
试验 5	✓	✓	—	99.2	97.3	97.3	7.24	3.93
试验 6	✓	—	✓	99.2	98.8	96.2	6.79	3.65
试验 7	—	✓	✓	99.2	97.9	96.6	9.07	4.82
试验 8	✓	✓	✓	99.2	96.0	98.1	4.49	3.58

从表 2 的消融实验可以看出,在原 YOLOv11n 模型基础上引入 StarNet 替换主干后,参数量和模型大小分别降低了 24%和 23%,检测精度保持不变,证明了采用轻量级 StarNet 替换主干使得模型在保持性能的同时更加的轻量化;同时,采用轻量化 LTBD-Head 检测头和 C3k2_BlockStar 模块,模型的大小和参数量都有不同程度的降低;试验 5 和试验 6 分别是引入 StarNet 和采用 C3k2_BlockStar 模块、引入 StarNet 和采用 LTBD-Head 检测头,参数量和模型大小分别降低了 26.5%和 24.9%、31.1%和 30.2%,进一步降低了模型复杂度。试验 8 同时引入 StarNet 主干替换、C3k2_BlockStar 模块以及 LTBD-Head

检测头,模型的综合性能幅值达到最大,mAP 达到 99.2%,参数量减少 54.4%,模型的大小缩减为原来的 68%。由此可见,本文算法在保持高精度检测的同时大幅度降低了参数量和模型大小,满足了实时性的要求。

2.6 不同目标检测模型的性能对比

为了验证本文模型相比现有一阶段模型的优越性,将本文模型与常见的目标检测模型 YOLOv5n^[18]、YOLOv6^[19]、YOLOv8n^[20]、YOLOv9^[21]、YOLOv10n^[22]及 YOLOv11n^[23]在相同的试验条件下进行对比试验,结果如表 3 所示。

由表 3 数据可知,本文模型在 mAP 值、召回率、参数

表 3 各个检测模型对比

Table 3 Comparison of detection models

模型	mAP/ %	P/ %	R/ %	参数量/ ($\times 10^6$)	模型 大小/MB
YOLOv5n	98.9	97.2	97.1	9.55	5.3
YOLOv6	99.2	96.6	98.2	16.15	8.7
YOLOv8n	99.0	96.6	98.2	11.47	6.3
YOLOv9	99.2	97.6	97.1	76.88	41.1
YOLOv10n	99.1	97.1	95.9	8.64	5.8
YOLOv11n	99.1	97.1	97.4	9.85	5.23
本文模型	99.2	96.0	98.1	4.49	3.58

量及模型大小上均优于其他模型。其中,mAP 达到最高为 99.2%,参数量相比于 YOLOv5n、YOLOv6、

YOLOv8n、YOLOv9、YOLOv10n、YOLOv11n 分别减少了 53%、72%、61%、94%、48%、54%;模型大小分别减少了 32%、59%、43%、91%、38%、32%。试验结果表明,改进后的模型对于隧道红外图像中的炮孔识别效果更好,且更易于部署到硬件设备上。

2.7 热力图可视化对比

当前目标检测模型存在检测过程可解释性不足的问题。为增强模型的可解释性,本文采用 Gred-CAM 绘制热力图并与原图叠加,从而直观展示网络对关键特征的学习效果。如图 8 所示,相较基线模型,本文改进方法生成的热力图与样本的真实特征分布更具有一致性。具体而言,改进后的模型能更精确地聚焦于炮孔区域特征,对样本贡献度高的像素区域表现出更显著的激活响应,有效解释了模型的检测过程。




图 8 热力图效果对比

Fig. 8 Comparison of heat map effects

2.8 识别效果可视化分析比较

为了直观对比本文模型与常见检测模型的识别效果,

本文将对多种目标检测模型的识别效果进行了可视化分析,如图 9 所示。从图 9 可以看出,由于炮孔边缘出现不




图 9 本文模型与其他对比模型识别效果

Fig. 9 Recognition effect of this paper's model and other comparative models

规则或破裂且炮孔与背景的相似性,传统检测模型普遍存在误检现象,而本文提出的模型则表现出了较好的性能。实验结果充分证明了本模型在复杂的背景条件下对红外小目标的识别具备良好的识别能力,尤其适用于实际复杂的隧道环境下红外炮孔的检测。

3 结 论

现有隧道炮孔检测方法在检测精度及模型轻量化方面仍有提升空间,本文提出的改进的YOLOv11n轻量化模型对隧道红外炮孔识别准确率的提升以及模型权重的减少提供了一种新的途径。

针对隧道环境光照不足及尘雾干扰环境下,基于可见光炮孔图像难以准确识别炮孔,且对于红外图像用于炮孔识别鲜有研究。本文基于YOLOv11n算法提出轻量化YOLOv11n红外炮孔检测模型。引入StarNet网络替换原模型主干,减少模型复杂度,提高模型处理红外炮孔图像复杂特征的能力,使其捕捉更为精细的特征;采用C3k2_BlockStar模块,增强局部特征提取和跨通道信息融合,提高模型鲁棒性;引入LTBD-Head,进一步减少模型计算量,提升模型检测的速度。所提出的红外炮孔检测模型在保持高精度检测的同时,参数量为 4.49×10^6 ,模型大小为3.58 MB,相较于原YOLOv11n模型,参数量减少54%,模型大小降低32%,在不影响检测准确率的前提下,显著降低了模型的计算复杂度。与常见的一阶段目标检测模型YOLOv5n、YOLOv6、YOLOv8n、YOLOv9、YOLOv10n、YOLOv11n相比,参数量分别减少53%、72%、61%、94%、48%、54%;模型大小分别降低32%、59%、43%、91%、38%、32%。本文模型在检测精度、参数量及模型权重上均为最优,在隧道复杂环境下对红外炮孔具有较好的检测结果,为下一步自动化装药机器人自动化装药提供了理论基础。

参考文献

[1] 谭忠盛,吴金刚.我国隧道钻爆法施工技术回顾与展望[J].隧道建设(中英文),2023,43(6):899-920.
Tan Zhongsheng, Wu Jingang. Review and prospects of drilling and blasting tunnel construction technology in China [J]. Tunnel Construction, 2023, 43 (6): 899-920.

[2] 秦念稳.钻爆法隧道炸药智能化装填系统研究与应用[J].铁道建筑技术,2024(6):175-178,201.
Qin Nianwen. Research and application of intelligent explosives filling system for drilling-and-blasting tunnels[J]. Railway Construction Technology, 2024(6): 175-178, 201.

[3] 安振伟,张小勇,黎勇,等.智能现场混装炸药车的发展现状与展望[J].爆破,2025,42(2):140-145.
An Zhenwei, Zhang Xiaoyong, Li Yong, et al. Current

situation and prospect of intelligent on-site mixed-loading vehicles[J]. Blasting, 2025, 42(2): 140-145.

[4] 刘权,龚兵,伍高娃.基于改进YOLOv7的地下矿炮孔图像识别方法研究[J].有色金属(矿山部分),2023,75(6):1-6,25.
Liu Quan, Gong Bing, Wu Gaowa. Underground mine blast hole image recognition method based on improved YOLOv7 [J]. Nonferrous Metals (Mining Section), 2023, 75(6): 1-6, 25.

[5] 胡启国,刘洋,余芃林,等.基于CE-YOLOv8的炮孔识别方法[J].重庆交通大学学报(自然科学版),2024,43(11):130-138.
Hu Qiguo, Liu Yang, Yu Penglin, et al. Blast hole identification method based on CE-YOLOv8 [J]. Journal of Chongqing Jiaotong University (Natural Science), 2024, 43(11): 130-138.

[6] 岳中文,金庆雨,潘杉,等.基于深度学习的轻量化炮孔智能检测方法[J].煤炭学报,2024,49(5):2247-2256.
Yue Zhongwen, Jin Qingyu, Pan Shan, et al. Intelligent detection method of lightweight blasthole based on deep learning [J]. Journal of China Coal Society, 2024, 49(5): 2247-2256.

[7] Zhang W Z, Sun Z Z, Mei J, et al. Intelligent recognition and parameter acquisition of blastholes in rock tunnel based on improved Faster R-CNN [J]. Tunnelling and Underground Space Technology, 2024, 149: 105790.

[8] Pan S, Tian Z J, Qin Y F, et al. Intelligent blasthole detection of roadway working face based on improved YOLOv7 network [J]. Applied Sciences, 2023, 13(11): 6587.

[9] 张兴长,张奇,孙子正.基于深度学习的钻爆法隧道炮孔孔位智能识别研究[J].山东交通科技,2023(5):92-96.
Zhang Xingchang, Zhang Qi, Sun Zizheng. Intelligent identification of the blasting hole in drilling and blasting method for tunnel based on deep learning [J]. Shandong Jiaotong Keji, 2023(5): 92-96.

[10] 胥维,迟洪鹏,战凯.基于3D视觉的炮孔智能识别方法研究[J].黄金,2025,46(1):6-10.
Xu Wei, Chi Hongpeng, Zhan Kai. Research on intelligent blast hole recognition method based on 3D vision [J]. Gold, 2025, 46(1): 6-10.

[11] 金庆雨,岳中文,任猛,等.智能炮孔检测与路径规划系统设计与应用[J].煤炭科学技术,2024,52(11):186-196.
Jin Qingyu, Yue Zhongwen, Ren Meng, et al. Design and application of intelligent blasthole detection and

- path planning system [J]. Coal Science and Technology, 2024, 52(11): 186-196.
- [12] 童小钟, 赵宗庆, 苏绍璟, 等. 基于知识蒸馏自适应 DenseNet 的无人机对地目标可见光与红外图像融合[J]. 仪器仪表学报, 2024, 45(5): 20-32.
Tong Xiaozhong, Zhao Zongqing, Su Shaojing, et al. Fusion of visible and infrared images of ground targets by unmanned aerial vehicles based on knowledge distillation adaptive DenseNet[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 20-32.
- [13] 吕游, 郑茜, 齐欣宇, 等. 基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 175-184.
Lyu You, Zheng Qian, Qi Xinyu, et al. A study on fault recognition of photovoltaic module with infrared images based on improved EfficientNet [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 175-184.
- [14] 王亦君, 张露, 李燕. 基于多尺度感知的自适应无人机红外小目标检测[J]. 电子测量技术, 2026, 49(8): 55-66.
Wang Yijun, Zhang Lu, Li Yan. Adaptive UAV infrared small target detection based on multi-scale perception [J]. Electronic Measurement Technology, 2026, 49(8): 55-66.
- [15] 牟涛, 王代强. 基于改进 YOLOv11 光伏热斑小目标缺陷检测[J]. 电子测量技术, 2026, 49(6): 229-238.
Mu Tao, Wang Daiqiang. Defect detection of small targets based on the improved YOLOv11 photovoltaic hot spot[J]. Electronic Measurement Technology, 2026, 49(6): 229-238.
- [16] 孙溪成, 吕伏, 尹艺潼. 自适应特征增强的多尺度红外与可见光图像配准和融合算法[J]. 电子测量与仪器学报, 2025, 39(6): 242-254.
Sun Xicheng, Lyu Fu, Yin Yitong. Multi-scale infrared and visible image registration and fusion algorithm with adaptive feature enhancement [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 242-254.
- [17] Ma X, Dai X Y, Bai Y, et al. Rewrite the stars[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [18] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [19] Li C Y, Li L L, Jiang H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[PP/OL]. V1. (2022-09-07) [2025-11-05]. <https://doi.org/10.48550/arXiv.2209.02976>.
- [20] Varghese R, Sambath M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems(ADICS). IEEE, 2024: 1-6.
- [21] Wang C Y, Yeh I H, Mark Liao H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]//European Conference on Computer Vision, 2025: 1-21.
- [22] Wang A, Chen H, Liu L H, et al. YOLOv10: Real-time end-to-end object detection [J]. Advances in Neural Information Processing Systems, 2024, 37: 107984-108011.
- [23] Khanam R, Hussain M. YOLOv11: An overview of the key architectural enhancements[PP/OL]. V1. (2024-10-23) [2025-11-05]. <https://doi.org/10.48550/arXiv.2410.17725>.

作者简介

李亮川, 硕士, 工程师, 主要研究方向为机械自动化设计、钻爆法隧道大机施工装备研发。

E-mail: liliangc06@163.com

郭龙谊(通信作者), 硕士研究生, 主要研究方向为智能感知与机器人设计控制。

E-mail: longyig01@163.com