



面向边缘计算的矿区障碍检测模型研究

阮顺领 王京 顾清华 卢才武

引用本文:

阮顺领, 王京, 顾清华, 等. 面向边缘计算的矿区障碍检测模型研究[J]. 煤炭科学技术, 2024, 52(11): 141-152.

RUAN Shunling, WANG Jing, GU Qinghua. Research on mining area obstacle detection model for edge computing[J]. Coal Science and Technology, 2024, 52(11): 141-152.

在线阅读 View online: <https://doi.org/10.12438/cst.2024-0664>

您可能感兴趣的其他文章

Articles you may be interested in

煤矿掘进机井下巷道环境建模与障碍检测方法研究

Research on environmental modeling and obstacle detection method for underground roadway of coal mine tunneling machine
煤炭科学技术. 2020, 48(11): 12-18 <http://www.mtkxjs.com.cn/article/id/c76f3a80-21d9-4704-a53c-0dfb97824593>

煤矿安全监测监控体系中边缘计算模式研究

Research on edge computing mode in coal mine safety monitoring and control system
煤炭科学技术. 2022, 50(5) <http://www.mtkxjs.com.cn/article/id/b7b2e91a-40d9-4a4a-b8f0-d3e66858d450>

基于边缘计算的煤矿工作面甲烷监测模式探讨

Research on methane monitoring mode of coal mining face based on edge computing
煤炭科学技术. 2020, 48(12) <http://www.mtkxjs.com.cn/article/id/808742e3-79d4-488c-bb70-95103b3b2c29>

荒漠化露天矿土壤湿度监测模型的构建——以红沙泉矿区为例

Construction of soil moisture monitoring model in desertification open-pit mining area :taking Hongshaquan Mining Area as an example
煤炭科学技术. 2022, 50(2): 300-311 <http://www.mtkxjs.com.cn/article/id/c9ae7afb-480d-40e1-b608-b07e7eabb7ad>

基于役龄回退模型的露天矿卡车周期预防性维护策略

Periodic preventive maintenance strategy of open-pit mine truck based on age-reduction model
煤炭科学技术. 2023, 51(4): 209-214 <https://doi.org/10.13199/j.cnki.cst.2021-1236>

基于综合赋权云模型的露天矿岩体可爆性分级识别

Classification and identification of rock blastability in open-pit mine based on comprehensive weighted cloud model
煤炭科学技术. 2019(10) <http://www.mtkxjs.com.cn/article/id/bc5a74c0-aa17-4284-9a5c-b64f1ffbb51a>



关注微信公众号, 获得更多资讯信息



移动扫码阅读

阮顺领,王 京,顾清华,等.面向边缘计算的矿区障碍检测模型研究[J].煤炭科学技术,2024,52(11):141-152.
RUAN Shunling, WANG Jing, GU Qinghua, et al. Research on mining area obstacle detection model for edge computing[J]. Coal Science and Technology, 2024, 52(11): 141-152.

面向边缘计算的矿区障碍检测模型研究

阮顺领^{1,2,3},王 京^{1,4},顾清华^{1,2,4},卢才武^{1,2}

(1.西安建筑科技大学资源工程学院,陕西西安 710055;2.西安市智慧工业感知计算与决策重点实验室,陕西西安 710055;
3.西安优迈智慧矿山科技有限公司,陕西西安 710055;4.西安建筑科技大学矿山系统工程研究所,陕西西安 710055)

摘要:近年来,随着矿用卡车自动驾驶技术的兴起,使得矿区道路行车障碍物检测变得至关重要,基于深度学习的目标检测模型应用于矿区道路障碍检测取得了显著的效果,为矿用卡车自动驾驶技术的完善提供了可能。为解决现有模型应用于矿区障碍物检测,往往存在算法庞大与部署成本较高的问题,提出一种面向边缘计算平台的改进 YOLOv8 矿区道路障碍检测模型,该模型针对资源有限的边缘计算设备进行优化部署,以实现障碍物的快速、精准检测。该模型在特征提取阶段,引入深度可分离卷积和通道注意力机制,提高模型对障碍物整体特征提取能力,从而提升对不同尺寸障碍物的检测精度;特征融合阶段采用 BiFPN 网络结构,轻量化颈部网络并自适应地调整融合权重,减少冗余信息,提高特征的表达能力;使用局部卷积 PConv 对检测头进行重新设计,减少网络参数量以提高检测效率;最后,通过引入 Inner-CIoU 函数对边界框损失进行优化,加快模型收敛速度并提升边界框定位效果。实验结果显示,该网络在所使用的矿区障碍物数据集上,mAP@0.5 仅下降 0.05 的前提下,模型参数减少了 44%,推理时间缩短了 34%。相比其他轻量化检测网络,该模型在实验硬件设备上的检测速度更快,且在精度和轻量化之间实现了更好的平衡,为障碍物检测模型的实际部署提供了可行方案。

关键词:露天矿区;边缘计算;障碍检测;轻量化模型;模型部署

中图分类号:TD679;TP391;TP183 文献标志码:A 文章编号:0253-2336(2024)11-0141-12

Research on mining area obstacle detection model for edge computing

RUAN Shunling^{1,2,3}, WANG Jing^{1,4}, GU Qinghua^{1,2,4}, LU Caiwu^{1,2}

(1. School of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 2. Xi'an Key Laboratory of Perceptual Computing and Decision Making for Smart Industry, Xi'an 710055, China; 3. Xi'an U-Mine Intelligent Research Institute Co., Ltd., Xi'an 710055, China; 4. Institute of Mine System Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: In recent years, with the rise of autonomous driving technology for mining trucks, detecting obstacles on mining roads has become crucial. Object detection models based on deep learning have been applied to significant effect in detecting obstacles on mining roads, thereby providing possibilities for the improvement of autonomous driving technology for mining trucks. To address the issues of large algorithms and high deployment costs associated with existing models for mining obstacle detection, an improved YOLOv8 model tailored for edge computing platforms is proposed. This model is optimized for deployment on resource-constrained edge computing devices to achieve rapid and accurate obstacle detection. In this model, during the feature extraction stage, depthwise separable convolutions and channel attention mechanisms are introduced to enhance the model's ability to extract overall features of obstacles, thereby improving the detection accuracy of obstacles of various sizes. In the feature fusion stage, a BiFPN network structure is employed to lightweight the backbone network and adaptively adjust fusion weights, reducing redundant information and enhancing feature representation.

收稿日期:2024-05-21 策划编辑:常 琛 责任编辑:黄小雨 DOI: 10.12438/cst.2024-0664

基金项目:国家自然科学基金资助项目(52374160);陕西省技术创新引导专项基金资助项目(2023GXLH-062)

作者简介:阮顺领(1981—),男,河南周口人,教授,博士。Email: ruanshunling@xauat.edu.cn

通讯作者:王 京(2000—),男,陕西宝鸡人,硕士研究生。Email: wang7812926@xauat.edu.cn

The detection head is redesigned using local convolution PConv to reduce network parameter size and improve detection efficiency. Finally, by introducing the Inner-CIoU function for bounding box loss optimization, the model convergence speed is accelerated, and bounding box localization effectiveness is enhanced. Experimental results demonstrate that on the mining obstacle dataset used, while maintaining a decrease of only 0.05 in mAP@0.5, the model parameters are reduced by 44%, and the inference time is reduced by 34%. Compared to other mainstream detection networks, this model exhibits faster detection speed on the hardware devices used in the experiments and better balances the requirements of accuracy and lightweight, providing a feasible solution for the practical deployment of obstacle detection models.

Key words: open-pit mines; edge computing; obstacle detection; lightweight model; model deployment

0 引言

随着目标检测算法的不断成熟,无人矿卡在防碰撞方面表现良好。然而,现有的检测模型通常庞大而复杂,不符合矿区车辆无人驾驶系统中对轻量化和高效的需求。在实际应用中,高昂的部署成本也成为技术推广的重要障碍。因此,本文的核心关注点是研究并设计一种高效、低成本的轻量化矿区障碍物检测模型,旨在确保检测性能的同时,降低硬件和计算资源的需求,为矿区无人驾驶技术的实际应用提供可行且可持续的解决方案。

国内外一些学者已在矿区障碍物检测和模型轻量化方面做了一些研究。秦晓辉等^[1]针对矿山远距离障碍物难以识别问题,改进了YOLOv5检测模型,通过优化采样方法和解耦检测头,实现了白天和夜间场景下的障碍物识别。秦学斌等^[2]提出一种16线激光雷达与深度相机融合的煤矿卡车前障碍物检测方式,利用深度学习方法对雷达与相机数据分别检测,并融合结果,降低漏检情况,但存在小目标检测精度不高的问题。笔者等^[3]提出了一种多特征融合的露天矿区道路障碍物检测方法,精度达96.9%,召回率为89.9%,但模型较大,难以在边缘计算中部署。在模型轻量化方面,YUN等^[4]构建深度可分离残差模块,对SSD网络的VGG主干进行特殊处理,并采用轻量卷积核以减少参数量,提升检测速度,模型在Android平台上表现出色。LI等^[5]通过集成卷积注意力模块和视觉变压器,并选择性去除一些卷积层,改进了YOLOv5模型,实现了嵌入式设备上的快速检测,但精度较低。刘子洋等^[6]YOLOv8的颈部层进行改进,引入基于Transformer架构的BiFormer注意力机制和GSConv模块,在保证性能的前提下减小了模型规模,为端到端的工业部署提供新思路。胡峻峰等^[7]针对目标检测算法难以部署问题,使用轻量化的卷积核和特征融合方式。将YOLOv8的参数量和计算量分别降低为 2.6×10^6 和7.6 GFLOPs,降低了模型部署成本。

笔者借鉴了上述矿区道路障碍物检测方法和轻量级神经网络的优化策略,选择具有高精度和快速检测能力的YOLOv8模型,并进行相应改进,旨在解决算法模型较大、小目标检测能力弱和嵌入式设备上精度低等问题。主要目标是降低模型参数和运算量,提升检测速度,同时保持较高的检测精度,使模型在边缘计算平台上表现更佳。

1 矿区道路障碍检测轻量化模型

1.1 YOLOv8模型

YOLOv8是基于YOLOv5模型的一次重大更新版本,后者因其较早问世且性能优异,在工业领域得到了广泛应用。YOLOv8在骨干网络采用了C2f结构替代了C3结构,增强了梯度流和特征提取能力^[8],此外,YOLOv8对不同大小模型(n型、s型、m型、l型、x型)的缩放系数进行了微调,以满足不同场景的检测需求。在检测头方面,采用了解耦头(Decoupled-Head)结构^[9],将回归和分类任务分成独立的分支,取消了参数共享。这一结构在缓解两类任务内在冲突的同时,提升了模型性能。标签分配方面,YOLOv8使用了无锚框(Anchor-Free)思想^[10],减少了计算时间和资源消耗,同时避免了因锚框设置不合理导致的漏检和重复检测问题。此外,在损失函数方面,引入了Distribution Focal Loss与CIoU Loss,进一步提升了模型的性能和边界框回归的准确性。YOLOv8整体结构如图1所示。

1.2 基于改进YOLOv8的轻量化检测模型

现有矿区道路障碍检测模型存在模型体积较大、小目标检测能力弱、在嵌入式设备上性能表现较差的问题。为确保精度降低最小的情况下,极大程度降低模型参数量与运算量,提升模型检测速度,使其在边缘计算设备上达到速度和精度要求,本文对网络进行了以下具体改进:

1)针对露天矿道路障碍物尺度跨度不规则及障碍物遮挡等因素导致的漏检和误检问题,修改了C2f模块网络结构,引入带有通道注意力机制的MB-

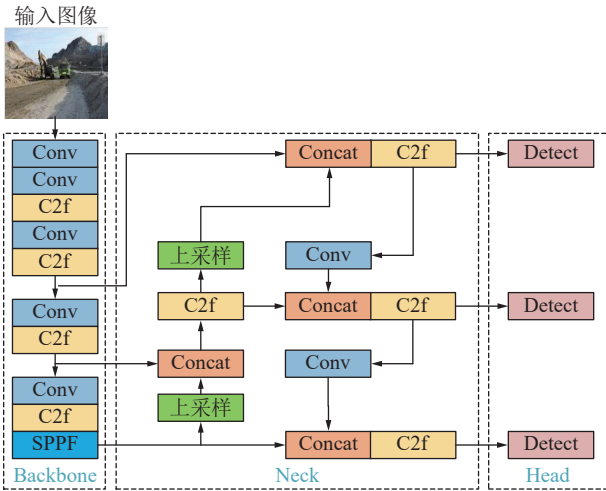


图 1 YOLOv8 网络结构

Fig.1 The network architecture of YOLOv8

Conv^[11] 模块, 提高对障碍物特征的提取能力, 从而提升检测精度。

2) 为解决矿区道路上坑洞、水坑等小目标障碍物因边界不清晰而难以检测的问题, 改进了颈部网络连接方式, 将特征提取网络的 P2 层信息引入颈部网络进行特征融合, 并采用 BiFPN^[12] 网络结构自适应地调整不同尺度特征的融合权重, 增强对小目标障碍物的特征提取能力, 同时减少模型参数。

3) 为了降低模型参数与计算量, 引入了局部卷积 PConv^[13] (Partial Convolution) 对检测头进行重新设计, 减少冗余计算, 提高检测速度。

4) 针对回归框匹配精度问题, 采用 Inner-CIoU^[14] 辅助边界框计算 IoU 损失, 更好地指导模型的训练和优化, 提升模型在复杂场景下的鲁棒性。改进后的轻量化检测模型如图 2 所示。

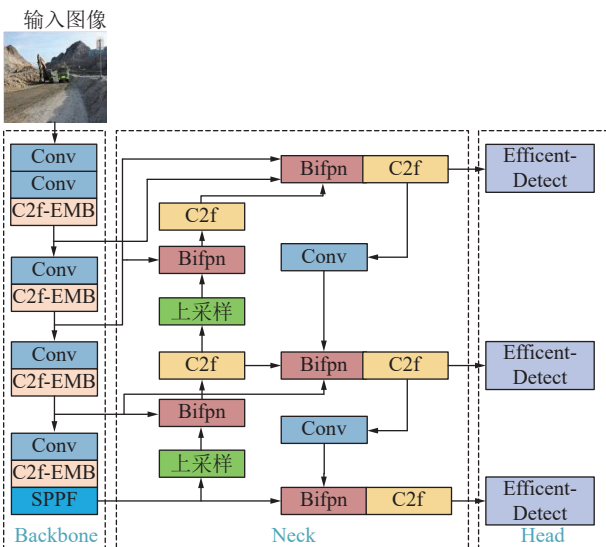


图 2 改进的 YOLOv8 结构

Fig.2 Improved YOLOv8 network structure

2 模型具体优化设计

2.1 特征提取阶段优化

露天矿区的障碍物具有多样性, 为增强主干网络的特征提取能力并尽可能降低其参数量, 在保留原有 Backbone 网络结构的基础上, 使用 MBConv 对 Bottleneck 层进行了修改, 从而形成新的特征提取模块 C2f-EMB, 其结构如图 3 所示。




图 3 C2f-EMB 模块结构

Fig.3 C2f-EMB module structure

特征提取模块的流程如下: 首先, 通过第一个 1×1 卷积对输入张量进行通道扩张。随后通过 Splitting 操作将扩张后的通道数分割为两部分。第一部分经过 n 个 MBConv 层处理, 第二部分则与 MBConv 模块的输出进行通道合并。最后, 通过第二个 1×1 卷积调整通道数, 得到最终的输出张量。这种通道分割和合并的方式能够更高效地提取和表示输入特征。在通道数的变化过程中, 通过不同的卷积操作, 还能实现通道数的灵活调整。

其中 MBConv 层结构如图 4 所示, 其中 H 为特征图的高度, W 为特征图的宽度, C 为特征图的通道数。首先, 通过一个 1×1 卷积扩展输入通道数; 随后进行 3×3 的深度可分离卷积, 用于提取图像特征; 接着引入 Squeeze-and-Excitation 机制, 对特征图进行通道注意力加权以调整特征矩阵; 然后通过 1×1 卷积压缩通道数, 并经过 Dropout 层进行随机失活, 以防止模型过拟合; 最后, 当输入通道数等于输出通道数时, 采用残差连接, 有助于梯度的顺畅流动。相较于原特征提取模块, 本次改进主要包括使用参数量更小的 3×3 深度可分离卷积来提取图像特征, 并引入通道注意力机制, 以确保在减少参数和计算量的同时保持高效性。

为实现对每个通道的全局信息提取、权重学习和自适应特征重标定, 引入 SE 注意力机制^[15] 如图 5 所示: 整个过程由压缩 (Squeeze)、激发 (Excitation)、门控 (Gating) 3 部分构成。压缩部分通过全局平均池化 (Global Average Pooling, GAP) 来捕捉每个通道的全局信息, 从而得到每个通道的全局平均激活值, 用于衡量通道的重要性。对于第 c 个通道, 全局平均




图4 MBConv 结构

Fig.4 MBConv module structure




图5 SE 注意力机制

Fig.5 Squeeze-and-Excitation attention mechanism

池化操作如式(1):

$$z_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (1)$$

式中: z_c 为通道 c 的全局描述; $x_c(i, j)$ 为输入特征图中通道 c 处的像素值。

激发部分使用全连接层学习每个通道的权重,以调整其重要性。通过两个全连接层,对每个通道的全局平均激活值进行学习。第一个全连接层用于降维,第二个全连接层用于升维,同时引入 Sigmoid 激活函数,产生激发度。对于第 c 个通道,激发度的计算如式(2):

$$s_c = \sigma [W_2 \delta (W_1 z_c)] \quad (2)$$

式中: W_1 和 W_2 为两个全连接层的权重矩阵; δ 为 ReLU 激活函数; σ 为 Sigmoid 激活函数。

使用激发度对原始特征进行加权,从而得到调整后的特征,使得模型可以更加关注对任务重要的通道。对于第 c 个通道,调整后的特征表示如式(3):

$$y_c = s_c x_c \quad (3)$$

式中: y_c 为第 c 个通道的调整后的特征, x_c 为原始的 第 c 个通道的特征。

2.2 特征融合阶段优化

露天矿区道路存在各种不同种类和大小的障碍物,例如落石和坑洞。这些障碍物通常外形不规则、大小不一,尤其在距离卡车较远时,容易与路面混淆,难以被有效检测。此外,由于这些障碍物的语义信息较少,容易导致目标丢失,特别是小尺寸障碍物,更容易出现漏检情况。

为进一步提升算法对小目标障碍物的检测性能,本文在原始模型中仅将 P3、P4、P5 层的特征提取输出送入融合网络的基础上,加入了 P2 层的输出结果,并按照图 6 所示的特征融合方式进行融合。此外,针对障碍物尺寸不一的情况,本文在 Neck 网络部分引入了 BiFPN (Bi-directional Feature Pyramid Network) 结构,通过多层级的特征融合,使模型能够在

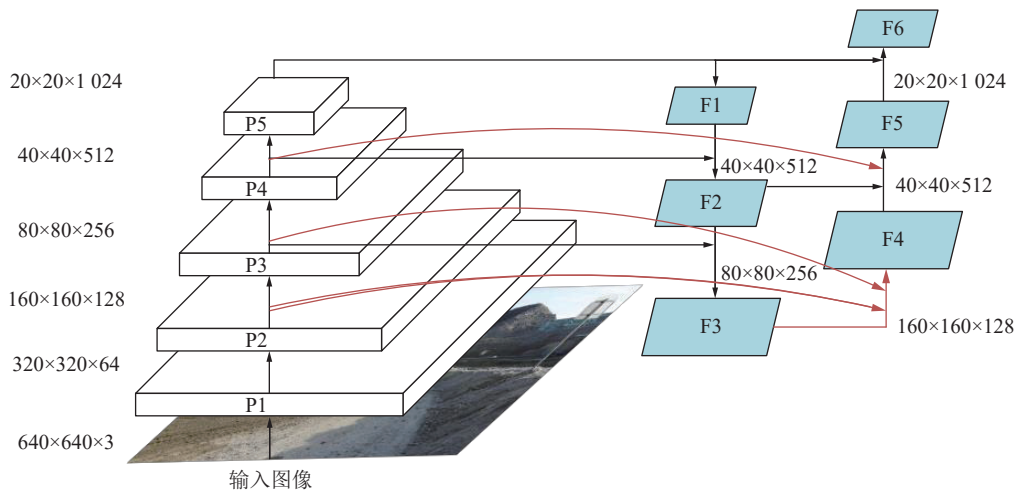


图6 特征融合结构

Fig.6 Features fusion structure

不同尺度上感知和理解目标,从而提高对不同尺度目标的检测性能。具体结构如图7所示。

传统的FPN结构采用自上而下的单向信息流,而YOLOv8延续了YOLOv5的融合策略,即采用PANet^[16]网络,在传统FPN的基础上增加了一条自下而上的信息流,以增强不同特征层的有效融合。然而,这种方法本质上仍是对不同特征层的简单叠加,难以解决不同大小目标的特征权重问题。BiFPN在此基础上进一步改进,通过删除仅有一条输入的节点,解决了单输入节点对特征网络造成的低贡献度和高运算量的问题。此外,BiFPN采用残差连接方式增强了语义信息的提取能力,并在原始输入和输出节点之间增加了额外的信息流,以确保在

不过多增大运算成本的前提下融合更多特征。式(4)、式(5)为BiFPN的计算表达式:

$$P_6^{td} = \text{Conv} \left(\frac{\omega_1 P_6^{in} + \omega_2 \text{Resize}(P_7^{in})}{\omega_1 + \omega_2 + \varepsilon} \right) \quad (4)$$

$$P_6^{out} = \text{Conv} \left(\frac{\omega'_1 P_6^{in} + \omega'_2 P_6^{td} + \omega'_3 \text{Resize}(P_5^{in})}{\omega'_1 + \omega'_2 + \omega'_3 + \varepsilon} \right) \quad (5)$$

式中,以P6层输出为例,其中 P_5^{in} 、 P_6^{in} 、 P_7^{in} 分别为第5、6、7层的输入; P_6^{td} 为由上而下路径中第6层的中间特性; P_6^{out} 为上而下路径中第6层的输出特性;Resize操作通常是下采样或上采样操作; ω 为相应权重参数; ε 为小常数,用于防止分母为0。




图7 不同网络结构对比

Fig.7 Comparison of different network structure

2.3 检测头优化

本文重点研究之一是实现模型的轻量化设计,以最终达到在计算资源有限的边缘计算平台实现更加快速、准确的检测效果。为此,在前两步网络改进的基础上,设计了新的检测头模块 Efficient-Detect, Efficient-Detect 延续了 YOLOv8 使用解耦头 (decoupled head) 的思想,共享底层特征提取层,减少模

型参数数量的同时,两个解耦头可以分别更加关注边界框坐标回归和目标类别分类任务,能够更好地提高多任务学习效率。在此基础上,本文引入局部卷积(PConv)优化检测头,其原理如图8所示。

图8所示,普通卷积是将整个输入特征图与卷积核进行卷积,输出特征图包含所有输入特征;深度/分组卷积是将输入特征图分成多组,每组分别进行

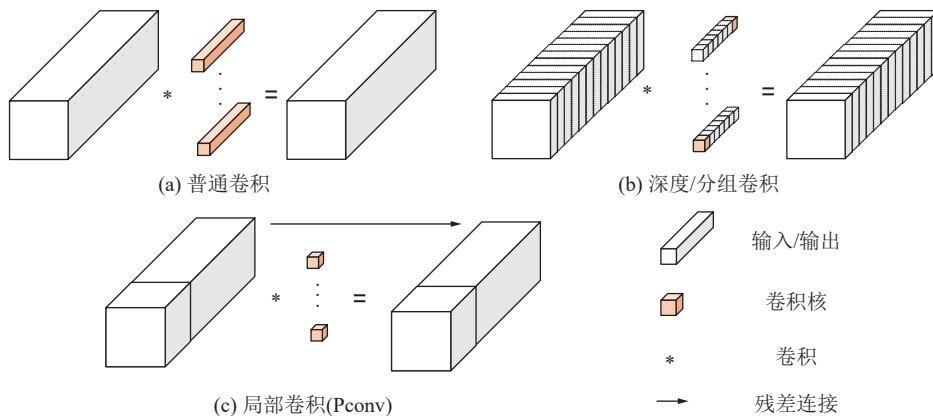


图8 不同卷积原理对比

Fig.8 Comparison diagram of different convolutional principles

卷积,并将结果拼接成输出特征图;而部分卷积则采取将输入特征一部分(有效区域)与卷积核进行卷积,忽略无效区域,输出特征图仅包含有效数据的信息。因此,采用部分卷积不仅可以避免普通卷积的易过拟合的弊端,还能降低参数量。提高计算效率,同时有效处理图像内容遮挡情况,提高鲁棒性。

矿区道路障碍物的不同通道之间的特征图往往具有高度相似性,进而可以利用特征图冗余优化计算成本:通过在部分通道上应用常规卷积(Conv)进行空间特征提取,其余通道保持不变;对于连续或规则的内存访问,将第一个或最后一个连续的 c_p 通道作为整个特征图进行计算。不失一般性。PConv的浮点运算次数为

$$\text{FLOPs} = H'W'k^2c_p^2 \quad (6)$$

PConv的内存访问情况为

$$H'W'2c_p + k^2c_p^2 \approx H'W'2c_p \quad (7)$$

其中, H' 和 W' 为特征图的宽和高; k 为卷积核的大小; c_p 为使用常规卷积的通道数,在实际实验中,PConv的FLOPs仅为常规卷积的1/16,内存访问量仅为常规卷积的1/4。因此,使用PConv可以有效减少冗余计算,更好地利用所部署设备的计算能力,从而具有更低的检测延迟。

2.4 损失函数优化

为了加速模型的收敛速度,使检测模型能更快地学习到矿区障碍物的特征,本文采取了对回归损失函数的相应优化。边界框回归损失函数是检测器定位的关键组成部分,定位精度在很大程度上取决于边界框回归,在检测器中具有不可替代的作用。IoU损失函数^[17]可以准确描述预测边界框与真实目标边界框之间的匹配程度,其定义如式(8):

$$\text{IoU} = \frac{|B^{\text{pred}} \cap B^{\text{gt}}|}{|B^{\text{pred}} \cup B^{\text{gt}}|} \quad (8)$$

式中,IoU为损失函数; B^{pred} 和 B^{gt} 分别为预测边界框和真实目标边界框,相应的损失定义如下:

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

基于IoU的损失函数已占据主导地位,基于IoU进一步添加新的损失项,提出了GIoU^[18]、DIoU^[19]、CIoU、EIoU^[20]和SIoU^[21]等新的损失函数。YOLOv8所采取的CIoU是在IoU基础上增加了一个距离损失项和形状损失项,其表达式如下:

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b^{\text{pred}}, b^{\text{gt}})}{c^2} + \alpha v \quad (10)$$

$$\alpha = \frac{v}{(1 - \text{IoU}) + v} \quad (11)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w^{\text{pred}}}{h^{\text{pred}}} \right)^2 \quad (12)$$

式中, b^{pred} 和 b^{gt} 分别为预测边界框和真实目标边界框的中心点; ρ 为欧几里得距离; c 为最小边界框的对角线长度; α 为正交平衡参数; v 用于衡量边界框长宽比的一致性; w^{gt} 和 h^{gt} 分别表示目标框的宽度和高度; w^{pred} 和 h^{pred} 分别表示预测框的宽度和高度。

为了弥补现有CIoU损失函数在露天矿障碍物检测任务中的泛化能力较弱且收敛速度较慢的问题,本文引入了Inner-CIoU函数辅助边界框计算损失,从而加速边界框回归过程。通过多次调试,选择了合适的尺度因子比 r 以控制辅助边界框的尺度大小,以能够克服原有CIoU在泛化能力和收敛速度方面的局限。Inner-IoU损失继承了IoU损失的一些特征,同时具备了自己的特点。Inner-IoU的原理描述如图9所示。




图9 Inner-IoU描述

Fig.9 Description of Inner-IoU

其公式表述如下:

$$b_l^{\text{gt}} = x_c^{\text{gt}} - \frac{w^{\text{gt}}r}{2}, b_r^{\text{gt}} = x_c^{\text{gt}} + \frac{w^{\text{gt}}r}{2} \quad (13)$$

$$b_t^{\text{gt}} = y_c^{\text{gt}} - \frac{h^{\text{gt}}r}{2}, b_b^{\text{gt}} = y_c^{\text{gt}} + \frac{h^{\text{gt}}r}{2} \quad (14)$$

$$b_l = x_c - \frac{w^p r}{2}, b_r = x_c^{\text{gt}} + \frac{w^p r}{2} \quad (15)$$

$$b_t = y_c - \frac{h^p r}{2}, b_b = y_c^{\text{gt}} + \frac{h^p r}{2} \quad (16)$$

$$\text{inter} = \left[\min(b_r^{\text{gt}}, b_r) - \max(b_l^{\text{gt}}, b_l) \right] \times \left[\min(b_b^{\text{gt}}, b_b) - \max(b_t^{\text{gt}}, b_t) \right] \quad (17)$$

$$\text{union} = (w^{\text{gt}}h^{\text{gt}})r^2 + (w^p h^p)r^2 - \text{inter} \quad (18)$$

$$\text{IoU}^{\text{inner}} = \frac{\text{inter}}{\text{union}} \quad (19)$$

式中： x_c^{gt} 和 y_c^{gt} 为真实框中心的横坐标和纵坐标； w^{gt} 和 h^{gt} 为真实框的宽度和高度； x_c 和 y_c 为预测框中心的横坐标和纵坐标； w^{p} 和 h^{p} 为预测框的宽度和高度； r 为尺度因子； b_l^{gt} 和 b_r^{gt} 为真实框在经过缩放后的左边界和右边界坐标； b_t^{gt} 和 b_b^{gt} 为真实框在经过缩放后的上边界和下边界坐标； b_l 和 b_r 为预测框在经过缩放后的左边界和右边界坐标； b_t 和 b_b 为预测框在经过缩放后的上边界和下边界坐标； inter 为预测框和真实框的交集区域面积； union 为预测框和真实框的并集区域面积； $\text{IoU}^{\text{inner}}$ 为内部交并比。将 Inner-IoU 应用于原有的 CIoU 结果如式(20)所示：

$$L_{\text{inner-CIoU}} = L_{\text{CIoU}} + \text{IoU} = \text{IoU}^{\text{inner}} \quad (20)$$

Inner-CIoU 损失继承了 CIoU 损失的一些特征，通过引入角度信息和对中心点距离的高斯权重，使得其在一些特定目标检测任务场景下有着不错的性能表现。Inner-CIoU 损失的范围与 CIoU 损失相同，为 $[0,1]$ 。由于辅助边界框与实际边界框之间仅存在尺度差异，损失函数的计算方法相同，Inner-CIoU 偏差曲线与 CIoU 偏差曲线相似。

3 实验与结果分析

3.1 数据集构建及实验准备

实验所采用的数据集来源于多个大型露天矿区道路场景，包含 909 张图片。这些图片涵盖了在不同光照条件和拍摄角度下的露天矿区道路障碍物，包括行人、水坑、矿卡、挖机和小车等常见行车障碍物。为了增加数据的多样性，使用了五种数据增强方法：加入噪声、改变亮度、翻转、平移和裁剪。通过这些方法，原始数据集扩充到 5 454 张矿区道路障碍物图像。这些图片可能包含多个种类和数量的障碍物信息。尽管数据集的总数量相对较小，但各类障碍物的标签数量丰富，足以满足障碍物检测模型的训练和测试需求，并有效提高模型性能及其泛化能力。最后，按照 8 : 2 的比例将数据集划分为训练集和测试集。

本文实验分别在 2 个平台完成，模型训练环节基于 Ubuntu 18.04 操作系统下，CPU 型号为：Intel(R) Core(TM) i9-10900X CPU @ 3.70GHz，GPU 型号为：NVIDIA GeForce RTX 3080(12G)，CUDA 版本为 v11.6，Python 版本为 3.8，深度学习框架为 Pytorch1.9.0。

模型测试环节在 CPU 采用 ARM 架构的 Raspberry Pi 4B 上进行，其图片如图 10 所示。其具体参数为：CPU: Broadcom BCM2711, 1.5 GHz, 64-bit,

ARM Cortex-A72 架构, RAM: 8G, 操作系统: Raspberry Pi OS(64-bit)。模型部署在 Raspberry Pi 4B 进行测试，可以更好的模拟模型在计算资源有限的硬件设备上的性能表现。




图 10 Raspberry Pi 4B 开发板

Fig.10 Raspberry Pi 4B development board

本次实验使用 $\text{mAP}@0.5$ 、 $\text{mAP}@0.5 : 0.95$ 、模型大小、模型参数量、FLOPs 以及模型在 Raspberry Pi 4B 上的推理时间来评估模型的性能表现。这里的 FLOPs 指的是浮点运算，FLOPs 数量越大，计算成本就越高，1 GFLOPs 等于 10^9 FLOPs；而 AP 指的是模型在某一类别下的平均精度， mAP 则表示在多个类别上计算 AP 的平均值。具体的计算公式如下所示：

$$\text{AP} = \int_0^1 P dR \quad (21)$$

$$\text{mAP} = \frac{\sum \text{AP}}{N} \quad (22)$$

式中， P 为在不同召回率下的精度； N 为类别总数； $\text{mAP}@0.5$ 为交并集 (IoU) 阈值为 0.5 时的 mAP ； $\text{mAP}@0.5 : 0.95$ 为不同 IoU 阈值 (0.5 到 0.95, 步长为 0.05) 上的平均 mAP 。

3.2 本文算法实验结果

使用改进后的轻量化模型在自制数据集上进行训练与测试，图 11 展示了改进模型的性能指标可视化曲线，包括训练集和验证集的置信度损失、边界框损失、类别损失曲线，以及精确度、召回率、 $\text{mAP}@0.5$ 、 $\text{mAP}@0.5 : 0.9$ 四个性能指标曲线，横坐标表示迭代次数，纵坐标为具体数值。

观察损失曲线可以发现，改进后的模型在训练集和验证集上各项指标收敛速度较快，特别是关闭 mosaic 操作的后 10 轮训练进一步加快了收敛速度。最终， $\text{mAP}@0.5$ 稳定在 90.9%， $\text{mAP}@0.5 : 0.9$ 稳定在 71.6%，准确率接近 93.7%，召回率接近 88.7%。

图 12 展示了基线模型 YOLOv8n 与本文模型在部分验证集上的性能表现。可以看出，在简单场景

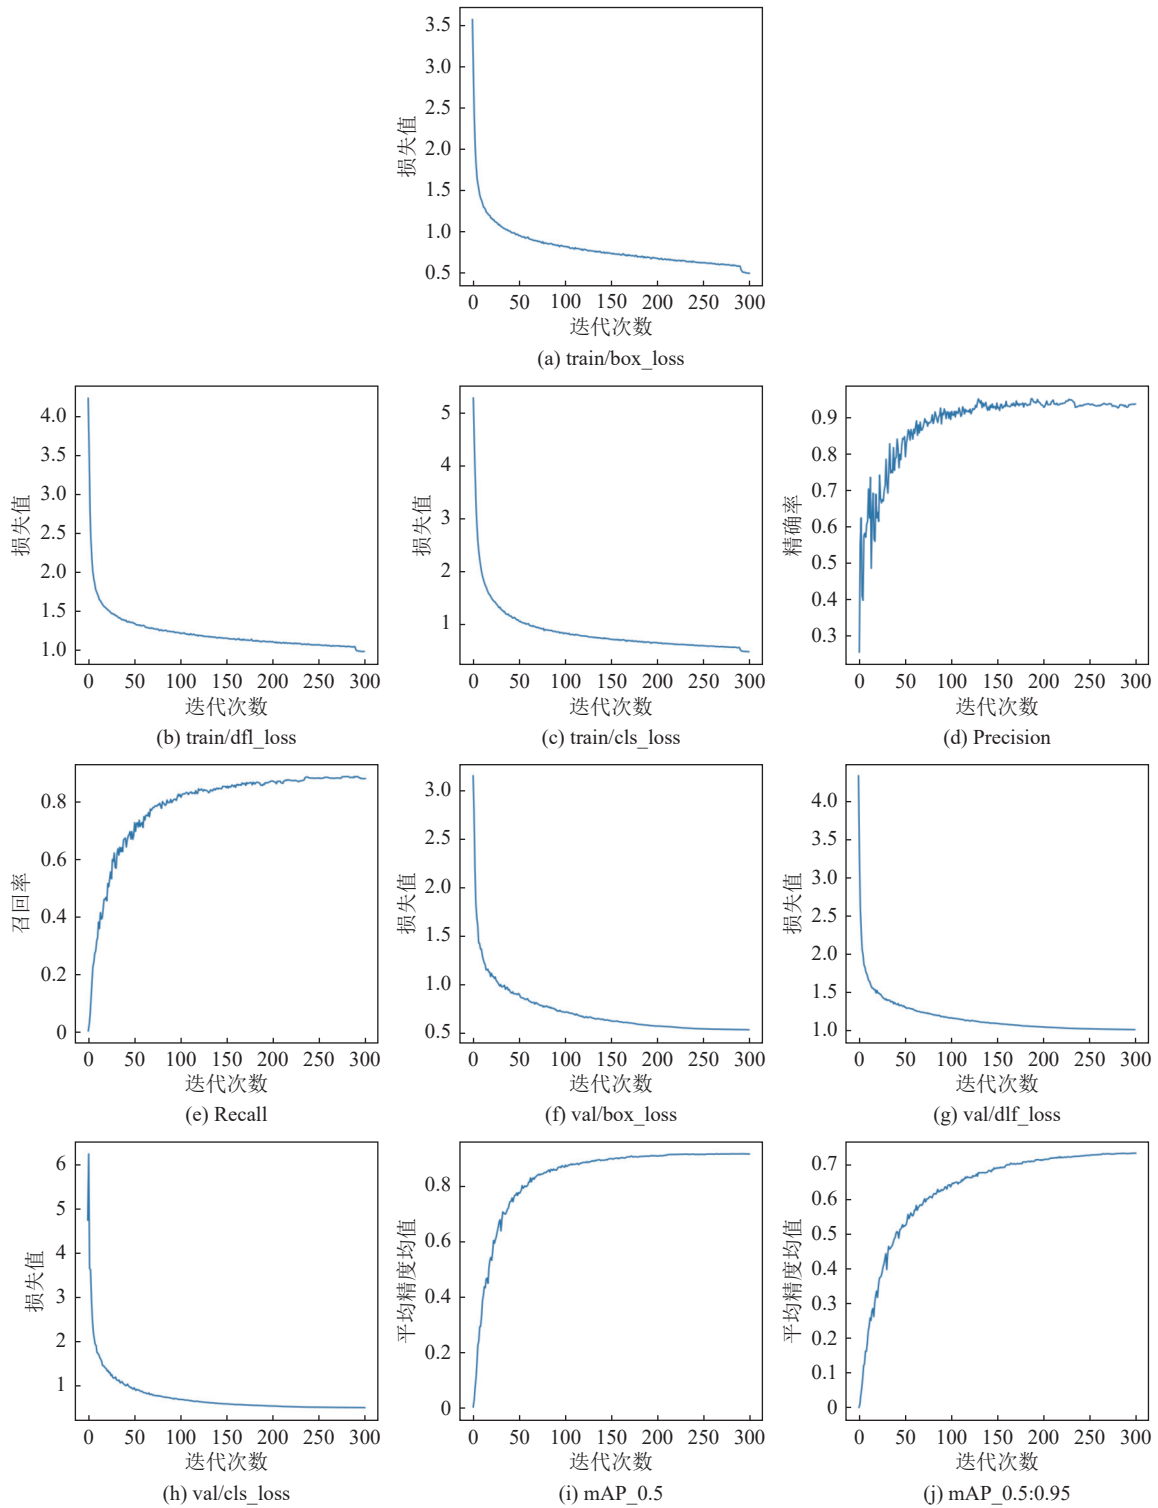


图 11 本文模型性能曲线

Fig.11 Performance curve of the model in this paper

下,二者表现差距不大,但在较复杂场景下,如第二幅图中坑洞与道路的语义信息高度相似,或第三、四幅图存在远距离小目标时,本文模型由于在特征提取和特征融合阶段的改进,能够更准确地判断车辆前方所有障碍物,极大程度避免了漏检情况的发生。

3.3 消融实验

为了验证改进后的网络模型的有效性及各改进模块的影响,本实验进行了消融实验对比,对各阶段改进后的模型分别命名为 Method 1、Method 2、Method 3 和 Method 4。其具体对比结果见表 1。

表 1 中, YOLOv8n 以及 Method 1、Method 2、




图 12 本文模型与基线模型部分结果对比

Fig.12 Comparison of partial results between the model proposed in this paper and the baseline model

表 1 消融实验结果

Table 1 The ablation experiment results

模型	EMBC	BiFPN	PConv	Inner-CIoU	mAP@0.5	mAP@0.5:0.95	模型大小/MB	GFLOPs/(10 ⁹ 次·s ⁻¹)
YOLOv8n					0.914	0.731	6.2	8.2
Method 1	√				0.928	0.739	6.6	7.6
Method 2	√	√			0.918	0.722	4.5	6.8
Method 3	√	√	√		0.895	0.685	3.6	3.6
Method 4	√	√	√	√	0.909	0.716	3.6	3.6

Method 3 均使用 CIoU 作为损失函数, Method 4 采用 Inner-CIoU 作为损失函数, 由表中数据可见, 将骨干网络在将 C2f 模块的 Bottleneck 层替换为 EMBC 后, 其 mAP@0.5 由 0.914 上升至 0.928, mAP@0.5 : 0.95 由 0.731 上升至 0.739, GFLOPs(每秒 10 亿次浮点运算次数)由 8.2 降至 7.6, 这表明 MBConv 模块的引入不仅降低了运算量, 还使特征图更加关注障碍物本身, 提高了重要特征的权重, 进而提升了模型的精度。此外, 轻量型颈部和检测头的设计, 使得模型大小从 6.6MB 降至 3.6MB, GFLOPs 也从 7.6 降

至 3.6, 进而导致 Method 3 的精度最低, 表明新的特征融合方法和检测头的引入, 以少量的精度下降换取大量的模型体积和参数量的减少, 随着 Method 4 中 Inner-CIoU 的引入, 使得精度有所回升, 最终实现了精度与速度的良好平衡。

图 13 展示了 YOLOv8n 原始结构的 C2f 特征提取模块和改进后的 C2F-EMBC 特征提取模块在障碍物检测中的 Grad-CAM 对比图。从图中可以看到, 原始网络结构对障碍物中心区域和边缘区域的关注度相对较低。相较而言, 改进后的 C2F-EM-

BC 结构对各种障碍物的敏感程度整体高于原模型,尤其在障碍物中心区域的热度显著提升。结合二者的 mAP 值与注意力热力图分析,得出 C2F-EMBC 特征提取模块更适合矿区道路障碍物检测场景。

图 14 展示了模型在训练过程中使用 CIoU 和 Inner-CIoU 的框回归损失对比。图中横坐标为迭代次数;纵坐标为损失值。在训练的初始阶段,Inner-

CIoU 的起始损失值明显低于 CIoU,并且在前 50 轮中,Inner-CIoU 的损失下降速度显著快于 CIoU。直到训练结束,Inner-CIoU 的损失值始终低于 CIoU。在训练的最后 10 个 epoch 关闭了 mosaic 操作,以进一步提升精度。从图中可以明显看到,在这最后 10 个 epoch 中损失值显著下降。综上所述,Inner-CIoU 的使用有助于模型更准确地定位目标位置,确保模型具有更好的检测性能。

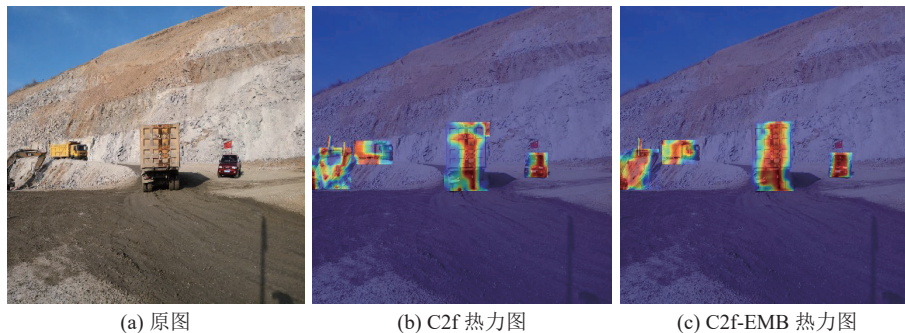


图 13 C2f 与 C2f-EMBC 热力图对比

Fig.13 Comparison of heatmaps between C2f and C2f-EMBC

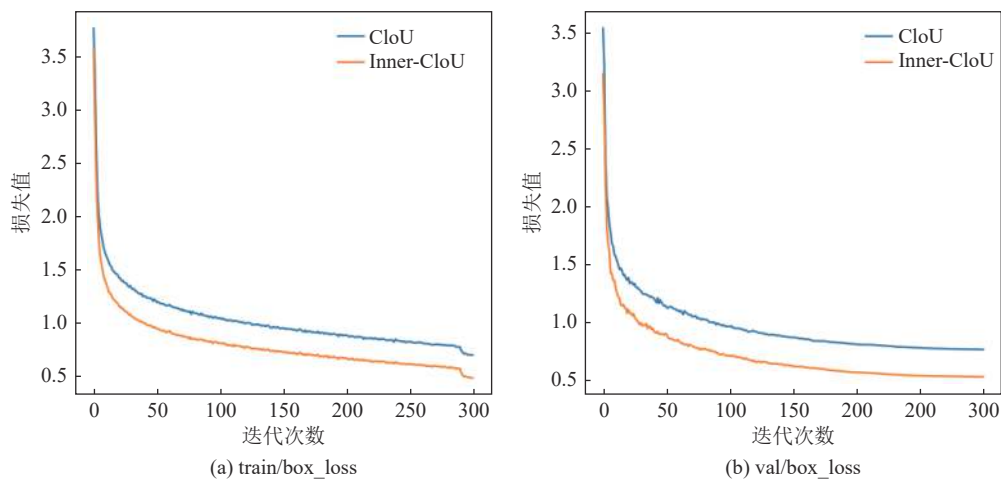


图 14 box_loss 对比

Fig.14 box_loss comparison chart

3.4 对比实验

模型的轻量化主要是通过牺牲部分精度的前提下提高检测速度,以满足对障碍物进行实时、快速检测的需求。因此本文将分两组实验分别进行对比,一组选择与部分小体积的单阶段检测模型进行对比,另一组选取了与两种嵌入式设备中使用频率较高的检测模型进行对比。为了确保模型在低算力的 Raspberry Pi 4B 上能够更好地发挥性能,上述模型首先通过 PyTorch 转换为 ONNX 模型,然后利用 ONNX Runtime 进行运行以适应嵌入式系统的资源限制。相较于 PyTorch 框架,ONNX 表现出更好的性能。

这一结果的原因在于 ONNX 本质上是一种中间模型表现格式,不依赖于特定框架的细节。此外,通过使用 ONNX Runtime 这样一个专门用于在嵌入式系统上运行 ONNX 模型的运行时库,有助于提升 ONNX 模型在嵌入式系统上的性能。

由表 2 可见,相较于原始的 YOLOv8n 模型,改进后的模型在 mAP@0.5 和 mAP@0.5 : 0.95 上略有下降。然而,由于颈部和头部网络的轻量化效果,改进后的模型参数减少了近 44%,模型大小减少了 40%,GFLOP 也从 8.2 降低至 3.6,推理时间减少了 34%。整体而言,改进后的模型在满足轻量化任务的

同时,性能仍然令人满意。与其他先进的 YOLO 系列模型相比, YOLOv5s 在 mAP@0.5 方面表现最佳,但模型较大,推理时间最长;此外,改进后的模型相对于 YOLOv5n,尤其在 mAP@0.5 : 0.95 上表现更

好,而且参数量、模型大小、FLOPs 以及推理时间都明显优于其他先进的 YOLO 系列模型。总体而言,改进后的模型在略微降低精度的前提下,实现了显著的速度提升。

表 2 不同模型性能对比

Table 2 Different model performance comparison

模型	mAP@0.5	mAP@0.5 : 0.95	参数量/ 10^6	模型大小/MB	GFLOP/s	Raspberry Pi上推理时间/ms
YOLOv5n	0.901	0.604	1.78	3.82	4.1	471.9
YOLOv5s	0.927	0.637	7.04	13.7	16.0	1 036.4
YOLOv7-tiny	0.916	0.659	6.03	12.3	13.2	756.4
YOLOv8n	0.914	0.731	3.01	6.2	8.2	672.4
Ours	0.909	0.716	1.69	3.6	3.6	446.1

由表 3 可见,本文提出的模型在 mAP@0.5 和 mAP@0.5:0.95 两项指标上均明显优于其他两个模型,彰显了更为卓越的检测准确性;虽然在参数量和模型大小方面稍逊于前两者,但由于其良好适配性,其在 Raspberry Pi 上的推理时间显著优于其他两者。

这一结果不仅证实了本文模型在适应嵌入式设备上具有更高的检测精度和更好的适配性,同时也强有力地证明了本文所提出的改进方案的有效性,为轻量化检测模型在精度和速度的平衡方面提供了极大的保障。

表 3 常见嵌入式设备模型性能对比

Table 3 Performance comparison of common embedded devices models

模型	mAP@0.5	mAP@0.5:0.95	参数量/ 10^6	模型大小/MB	GFLOP/s	Raspberry Pi上推理时间/ms
YOLOv5-Lite	0.749	0.499	0.78	1.72	0.73	528.8
YOLO-FastestV2	0.523	0.241	0.24	1.08	0.21	631.4
Ours	0.909	0.716	1.69	3.6	3.6	446.1

4 结 论

1)针对现有矿区障碍检测算法模型较大、复杂场景适应性差等问题,提出一种基于改进 YOLOv8n 的矿区障碍轻量化检测模型,准确率几乎不变的情况下,模型参数降低了 44%,推理时间减少了 34%,并且提升了对远距离小目标的检测能力。

2)颈部网络所采用的 BiFPN 结构以及重新设计的残差连接模块,能自适应调节小目标障碍物的融合权重,增强网络对远距离小目标障碍的特征表达能力,更好读取其语义信息,避免漏检情况发生。

3)轻量化检测头的设计虽能极大降低模型参数量与运算量,但对整体精度影响较大,需谨慎考虑使用。

4)使用 Inner-CIoU 能加快模型的收敛速度,提升模型检测性能,但针对不同数据集,需选取适合的缩放因子,以实现更优训练结果。

参考文献(References):

[1] 秦晓辉,黄启东,常灯祥,等.基于改进 YOLOv5 的露天矿山目

标检测方法[J].湖南大学学报(自然科学版),2023,50(2):23-30.

QIN Xiaohui, HUANG Qidong, CHANG Dengxiang, et al. Object detection method for open-pit mine based on improved YOLOv5[J]. Journal of Hunan University (Natural Sciences), 2023, 50(2): 23-30.

[2] 秦学斌,薛宇强,景宁波,等.露天煤矿自动驾驶矿卡车前障碍物检测算法研究[J/OL].金属矿山,1-12[2024-01-15].<http://kns.cnki.net/kcms/detail/34.1055.TD.20220906.1527.002.html>.

QIN Xuebin, XUE Yuqiang, JING Ningbo, et al. Research on obstacle detection algorithm for autonomous driving mine trucks in open-pit coal mines[J/OL]. Metal Mine, 1-12[2024-01-15].<http://kns.cnki.net/kcms/detail/34.1055.TD.20220906.1527.002.html>.

[3] 阮顺领,鄢盛钰,顾清华,等.基于多特征融合的露天矿区道路负障碍检测[J].煤炭学报,2024,49(5):2561-2572.

RUAN Shunling, YAN Shengyu, GU Qinghua, et al. Negative obstacle detection on open pit roads based on multi-feature fusion[J]. Journal of China Coal Society, 2024, 49(5): 2561-2572.

[4] YUN J T, JIANG D, LIU Y, et al. Real-time target detection method based on lightweight convolutional neural network[J]. Frontiers in Bioengineering and Biotechnology, 2022, 10: 861286.

- [5] LI S, LIU S B, CAI Z H, et al. TC-YOLOv5: rapid detection of floating debris on raspberry Pi 4B[J]. *Journal of Real-Time Image Processing*, 2023, 20(2): 17.
- [6] 刘子洋, 徐慧英, 朱信忠, 等. Bi-YOLO: 一种基于 YOLOv8n 改进的轻量化目标检测算法[J]. *计算机工程与科学*, 2024, 46(8): 1444-1454.
LIU Ziyang, XU Huiying, ZHU Xinzong, et al. Bi-YOLO: an improved lightweight object detection algorithm based on YOLOv8n[J]. *Computer Engineering & Science*, 2024, 46(8): 1444-1454.
- [7] 胡峻峰, 李柏聪, 朱昊, 等. 改进 YOLOv8 的轻量化无人机目标检测算法[J]. *计算机工程与应用*, 2024, 60(8): 182-191.
HU Junfeng, LI Baicong, ZHU Hao, et al. Improved YOLOv8 lightweight UAV target detection algorithm[J]. *Computer Engineering and Applications*, 2024, 60(8): 182-191.
- [8] WANG X Q, GAO H B, JIA Z M, et al. BL-YOLOv8: An improved road defect detection model based on YOLOv8[J]. *Sensors*, 2023, 23(20): 8361.
- [9] LOU H T, DUAN X H, GUO J M, et al. DC-YOLOv8: small-size object detection algorithm based on camera sensor[J]. *Electronics*, 2023, 12(10): 2323.
- [10] LI Y T, FAN Q S, HUANG H S, et al. A modified YOLOv8 detection network for UAV aerial image recognition[J]. *Drones*, 2023, 7(5): 304.
- [11] TAN M, LE Q. Efficientnetv2: Smaller models and faster training[C]//International conference on machine learning. PMLR, 2021: 10096-10106.
- [12] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 10778-10787.
- [13] CHEN J R, KAO S H, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada. IEEE, 2023: 12021-12031.
- [14] ZHANG H, XU C, ZHANG S J. Inner-IoU: more effective intersection over union loss with auxiliary bounding box[EB/OL]. 2023: 2311.02877. <https://arxiv.org/abs/2311.02877v4>
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 7132-7141.
- [16] WANG K X, LIEW J H, ZOU Y T, et al. PANet: few-shot image semantic segmentation with prototype alignment[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South). IEEE, 2019: 9196-9205.
- [17] ZHOU D F, FANG J, SONG X B, et al. IoU loss for 2D/3D object detection[C]//2019 International Conference on 3D Vision (3DV). Quebec City, QC, Canada. IEEE, 2019: 85-94.
- [18] REZATOFIHI 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, CA, USA. IEEE, 2019: 658-666.
- [19] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993-13000.
- [20] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146-157.
- [21] GEVORGYAN Z. SIoU loss: more powerful learning for bounding box regression[EB/OL]. 2022: 2205.12740. <https://arxiv.org/abs/2205.12740v1>