

# 基于深度学习的轻量化炮孔智能检测方法

岳中文<sup>1</sup>, 金庆雨<sup>1</sup>, 潘杉<sup>2</sup>, 颜文婧<sup>3</sup>, 覃逸峰<sup>2</sup>, 陈震<sup>1</sup>

(1. 中国矿业大学(北京) 力学与土木工程学院, 北京 100083; 2. 中国矿业大学(北京) 人工智能学院, 北京 100083; 3. 北京工商大学 电商与物流学院, 北京 100048)

**摘要:**在隧道(巷道)钻爆法施工过程中,智能装药可以取代人工作业,减少装药作业中危险事故的发生。然而,隧道中光线条件差、炮孔目标小和掌子面裂隙等因素会造成智能装药时炮孔的错检和漏检,同时车载计算机有限的算力也是制约炮孔识别大模型使用的难点。MCIW-2深度学习模型,可以解决在隧道掘进作业环境中的高精度炮孔检测和实时性部署问题。模型根据采集到的炮孔图像尺寸特征采取自适应锚框聚类算法优化检测框的长宽比尺寸参数;采用了具有动态非单调聚焦机制的损失函数  $W_{IoU}$ (Wise Intersection over Union),通过优化边框回归的损失应对低质量炮孔图片的挑战实现了高精度检测;采用了 MobileNetV3-Small 网络与 CBAM(Convolutional Block Attention Module)注意力机制构建了主干网络结构,减少了模型参数保证了检测准确率,满足车载设备的轻量化部署需求。经实验证明,MCIW-2模型在炮孔识别精确率方面达到了96.18%,检测速度达到了59 fps。与基准YOLO(You Only Look Once)系列目标检测模型文件最小的模型相比,所构建的轻量化炮孔智能检测模型减小了75.86%,模型文件仅为2.80 Mb,优于YOLO系列的基准目标检测模型。使用MCIW-2深度学习模型对工作面现场视频进行测试,实现了快速、精确地检测炮孔,测试结果表明,该模型适用于智能装药工程的轻量化部署需求,具有良好的适应性,在综合性能方面具有显著优势。

**关键词:**炮孔检测;轻量化模型;目标检测;深度学习

**中图分类号:** TP391.4; TD235 **文献标志码:** A **文章编号:** 0253-9993(2024)05-2247-10

## Intelligent detection method of lightweight blasthole based on deep learning

YUE Zhongwen<sup>1</sup>, JIN Qingyu<sup>1</sup>, PAN Shan<sup>2</sup>, YAN Wenjing<sup>3</sup>, QIN Yifeng<sup>2</sup>, CHEN Zhen<sup>1</sup>

(1. School of Mechanics and Civil Engineering, China University of Mining and Technology-Beijing, Beijing 100083, China; 2. School of Artificial Intelligence, China University of Mining and Technology-Beijing, Beijing 100083, China; 3. School of E-Business and Logistics, Beijing Technology and Business University, Beijing 100048, China)

**Abstract:** In the construction process of tunnel (roadway) drilling and blasting, intelligent charging can replace manual operation and reduce the occurrence of dangerous accidents in charging operation. However, some factors such as poor light conditions in the tunnel, small blasthole targets, and cracks in the tunnel face will cause the misdetection and missed detection of blastholes during intelligent charging. At the same time, the limited computing power of the vehicle-mounted computer is also a difficulty that restricts the use of large models for blasthole identification. The MCIW-2 deep learning

收稿日期: 2023-04-30 修回日期: 2023-07-31 责任编辑: 王凡 DOI: 10.13225/j.cnki.jccs.2023.0557

基金项目: 国家重点研发计划资助项目(2021YFC2902103)

作者简介: 岳中文(1975—),男,安徽淮南人,教授,博士生导师。E-mail: zwyue75@163.com

通讯作者: 颜文婧(1985—),女,安徽淮南人,讲师,博士。E-mail: yanwenjing@btbu.edu.cn

引用格式: 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.



移动阅读

model can solve the problem of high-precision blasthole detection and real-time deployment in the tunnel excavation environment. According to the size characteristics of the collected blasthole images, the model adopts the adaptive anchor frame clustering algorithm module to optimize the aspect ratio size parameters of the detection frame. The loss function  $W_{IoU}$  (Wise Intersection over Union) with a dynamic non-monotonic focusing mechanism is used to deal with the challenge of low-quality blasthole images for achieving a high-precision detection. The MobileNetV3-Small network and CBAM (Convolutional Block Attention Module) are used to build a backbone network structure, reducing model parameters to ensure detection accuracy and meet the lightweight deployment requirements of vehicle equipment. Experiments have proved that the MCIW-2 model has reached 96.18% accuracy in blasthole recognition, and the detection speed has reached 59 fps. Compared with the benchmark YOLO (You Only Look Once) series target detection model with the smallest file, the lightweight blasthole intelligent detection model constructed is reduced by 75.86%, and the model file is only 2.80 Mb, which is better than the benchmark target detection model of the YOLO series. The MCIW-2 deep learning model is used to test the live video of the working face, and the rapid and accurate detection of blasthole is realized. The test results show that the model is suitable for the lightweight deployment requirements of intelligent charge engineering, has a good adaptability, and some significant advantages in comprehensive performance.

**Key words:** blasthole detection; lightweight model; object detection; deep learning

钻爆法是隧道(巷道)工程施工的主要手段。工人在装药作业过程中长期面临着劳动强度大、施工环境恶劣和施工效率低等问题,随着现代化智能信息技术的发展,面向隧道(巷道)施工过程研究智能装药技术和改良隧道(巷道)施工过程中的装药作业方法,可以保障施工人员的健康情况和生命安全。2015年中国提出了“中国制造2025”战略,发展智能制造、智能装备、智能生产是其主要内涵<sup>[1]</sup>,智能装药符合国家战略,是实现隧道中自动化的智能装药工艺隧道(巷道)施工的必然选择。

目标检测是计算机视觉领域一个重要的研究分支,其任务是判断图像中是否存在需要检测的目标,如果存在目标则输出检测目标所属类别和位置信息,智能装药车中的炮孔识别与定位就是一个目标检测任务。在智能装药的早期研究中,学者已基于传统的信息处理技术实现了炮孔自动识别。ADRIAN等<sup>[2]</sup>通过使用激光扫描仪测量钻孔,并将它们与预先加载的爆炸计划相匹配,通过“底漆-指示剂组件”实现炮孔定位,将炮孔装药自动化技术的研究推向了新的高度。李鑫等<sup>[3]</sup>设计了无线遥控寻孔和智能寻孔2种炮孔检测方式,通过基于炮孔特征量的图像识别技术,使用智能工业摄像机和激光传感器来获取炮孔的空间方位。

随着计算能力的提升,智能模型能够处理的数据量也越来越大,基于深度学习的目标检测方法已经在不同的应用领域凸显其卓越的优势<sup>[4]</sup>。当前主要基于深度学习的目标检测方法根据架构类型的不同可分为2种:以R-CNN(Region-CNN, R-CNN)系列<sup>[5-7]</sup>为

代表的两阶段目标检测算法,其架构是基于区域建议构建的;以YOLO系列<sup>[8-13]</sup>和SSD(Single Shot Detector, SSD)系列<sup>[14]</sup>为代表的单阶段目标检测算法,其架构是基于回归构建的<sup>[15]</sup>。近年来,一些基于深度学习的目标检测技术已经被应用到炮孔检测上。张万志<sup>[16]</sup>通过分别改进SqueezeNet轻量级的卷积神经网络和更深层的ResNet-51网络,构建了基于改进Faster R-CNN的单个炮孔和多个炮孔与多个困难炮孔的目标检测模型,通过进行炮孔图像多尺度、多层特征融合和距离约束的NMS(Non-Maximum Suppression, NMS)等方法的对比实验,获得了对单个炮孔快速高效的识别与定位,通过融合多层特征和基于距离约束NMS多个困难炮孔过滤,得到了高精度和高召回率的多个炮孔和困难炮孔的识别与定位。张也<sup>[17]</sup>使用R-CNN、Faster R-CNN、YOLOv2和SSD512网络结构分别构建井下矿炮孔识别算法,结果显示YOLOv2与SSD512在检测速度上较Faster R-CNN的快,但是在精度上没有Faster R-CNN的高。

虽然基于深度学习的炮孔检测模型已经具备一定的精度,然而,高精度的检测效果是在复杂深度学习中海量计算参数的支持下实现的,随着深度学习技术的进步,其实现训练和推理的计算成本也越来越高。随着现代工业智能互联网的兴起,越来越多的智能模型需要在资源受限的环境中运行才能够实现在领域中的应用。轻量化炮孔智能检测是一种轻量化网络框架的深度学习技术,可以在保证检测精度和速度的前提下,将炮孔检测模型精简至适合于在嵌入式平台上进行轻量化、实时性部署的智能检测方法。目前,

在炮孔检测深度学习模型领域中, 针对轻量化炮孔检测模型的相关研究还较少。轻量化高精度炮孔检测模型可部署到智能装药车上, 实现在本地完成炮孔检测任务, 对提高炮孔检测效率、推动隧道(巷道)工程智能化发展具有重要的意义。在本研究中, 笔者面向隧道掌子面的炮孔识别, 创新性构建了炮孔智能检测模型 MCIW-2, 提出炮孔检测的锚框长宽比聚类算法和轻量化炮孔智能检测模型, 最终实现了精度高、检测速度快和轻量化部署的炮孔智能检测模型。

## 1 轻量化炮孔智能检测

### 1.1 数据增强模块

为了获得更多样化的炮孔图片, 在原始炮孔图片数据集的基础上进行了 1/4 的切割, 如图 1 所示, 每一张图片分成左上、左下、右上、右下 4 张图片, 然后将切割后的图片数据与原始数据合并为最终的炮孔数据集。通过对数据集的切割, 可以获得更多局部的炮孔图片, 对丰富炮孔图片的多样性、提高炮孔检测模型的鲁棒性具有促进作用。




图 1 炮孔图片四分示意

Fig.1 Four-segment diagram of blasthole picture

在切割过程中, 相应的炮孔数据标注标签也需要重新划分, 如果遇到某个炮孔正处于标准 1/4 切割线上时, 通过设定最小中心距离切割法(切割过程不会切割到炮孔的前提下, 切割线交叉的中心点距离原炮孔图片中心点的距离最小)进行炮孔图片的扩增。该方法首先根据标准 1/4 切割线, 在炮孔标注框中筛选出符合条件的炮孔, 根据标注框的占比筛选出每一个炮孔标注框中左上  $x \leq 0.5$ 、右下  $x \geq 0.5$  和左上  $y \leq 0.5$ 、右下  $y \geq 0.5$  的炮孔。其次, 根据筛选出炮孔的  $x$  和  $y$  坐标的最小值和最大值, 分别构建水平和竖直的切割线, 并将其设为新的切割线。然后, 在图片中循环迭代所有的炮孔, 如果新的切割线上仍然存在炮孔, 则重复前面的筛选和标记步骤, 直到新设定的切割线上不再存在炮孔为止。最后, 从切割线的交叉点中选择距离原始炮孔图片中心点最近的点作为

最终的炮孔图片的切割线。具体操作流程如图 2 所示。

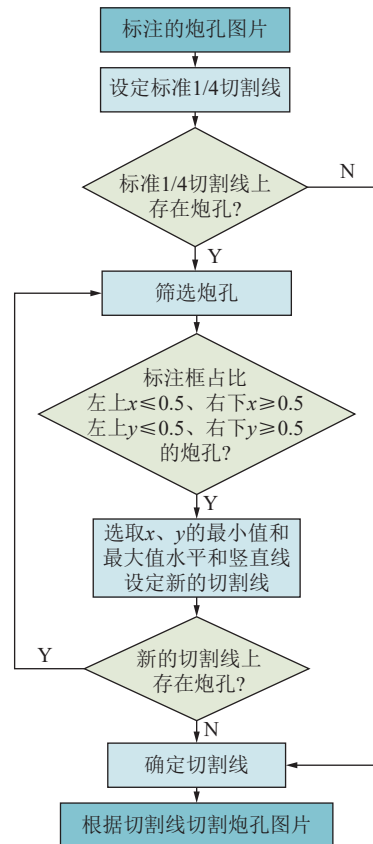


图 2 炮孔图片切割操作流程

Fig.2 Blasthole image cutting operation process

### 1.2 锚框参数聚类

基于深度学习的目标检测任务可分为基于锚框和无锚框 2 种类别, 笔者的炮孔智能检测模型是基于锚框设计的。锚框就是预先设定好的位置框, 在检测目标物体时作为位置的参考, 神经网络通过这些位置框判断其中是否包含检测的对象和在包括检测对象的基础上进行边框的微调, 从而合理的框选对象。在进行目标检测任务时, 通过预先设定不同尺度和不同位置的锚框, 可以将待检测图片中几乎全部位置和各种大小的物体都涵盖。

炮孔检测与其他目标检测的任务不同, 炮孔的形状基本上是接近圆形, 用来框选炮孔的锚框其长宽比与其他多类别的目标检测任务有所不同, 因此重新进行锚框长宽比的设定对提高炮孔检测的准确率是十分必要的。笔者在进行锚框尺寸选取时, 分别从聚类算法和聚类度量距离的选取 2 个方面进行自适应锚框聚类算法的设计和优化。一般的锚框参数是通过 K-means 聚类得到的, 但是 K-means 初始化是随机选取的  $k$  个点作为簇中心点, 这就容易造成聚类结果局

部最优,而 K-means++在选取第  $n+1$  个簇中心点时,是通过选取距离前  $n$  个簇中心点最远的那个点作为第  $n+1$  个簇中心,这更符合炮孔检测要达到的目标。

使用欧氏距离来计算簇中心与其他各点的距离为

$$d_1(p, \mu) = \sqrt{\sum_{i=1}^n (p_i - \mu_i)^2} \quad (1)$$

式中,  $d_1$  为各样本点距离簇中心的欧式距离;  $p$  为簇中的某个样本点;  $\mu$  为每个簇的中心点;  $n$  为每个簇中的样本点的个数;  $p_i$  为第  $i$  个样本点的属性值;  $\mu_i$  为第  $i$  个簇中心的属性值。

炮孔锚框的设定是为了与真实框进行比较,它们之间越匹配最终得到的炮孔检测效果越好,笔者将样本点与簇中心点之间的交并比 (Intersection over Union, IoU) 作为衡量锚框聚类的距离,这样更符合实际的需求, IoU 越大,样本点与簇中心点之间的距离就越小,其公式为

$$d_2(p, \mu) = \sum_{i=1}^n [1 - \text{IoU}(p_i, \mu_i)] \quad (2)$$

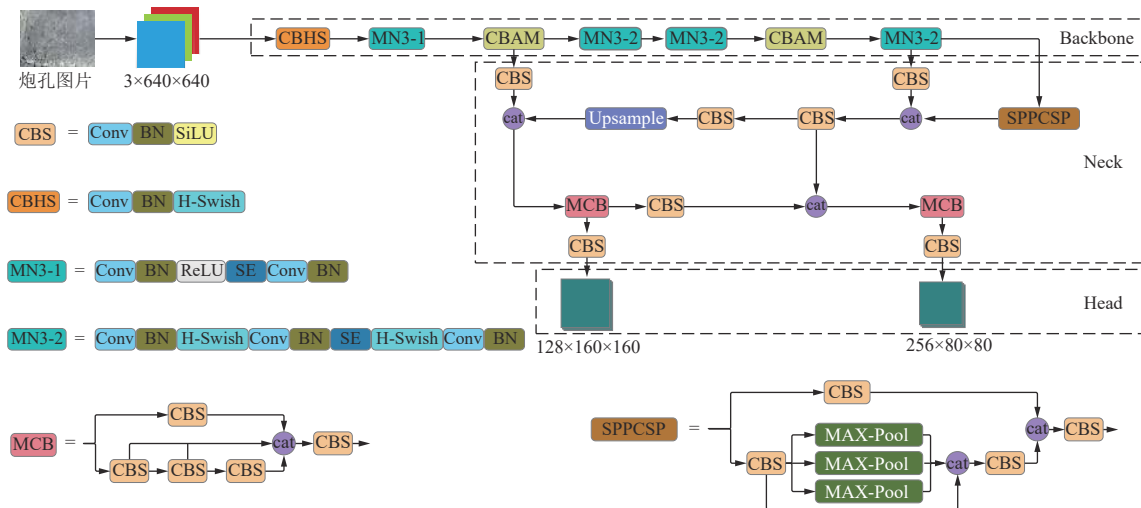


图3 轻量化炮孔智能检测模型 MCIW-2 结构

Fig.3 Structure diagram of lightweight blasthole intelligent detection model MCIW-2

### 1.3.1 Backbone 网络

卷积神经网络进行特征提取成为目标检测的主流方法,卷积神经网络的发展从 AlexNet<sup>[19]</sup>到 ResNet<sup>[20]</sup>,网络结构越来越深,性能不断的提高,但是由此带来参数计算量越来越大的问题,复杂度也越来越高,该问题造成对硬件的要求不断提高,影响技术的推广和应用<sup>[21]</sup>。2017 年谷歌提出了 MobileNet<sup>[22]</sup>轻量化网络模型,并将其不断升级迭代为 MobileNetv3-Small<sup>[23]</sup>

式中,  $d_2$  为各样本点距离簇中心的交并比损失。

通过设计的自适应锚框聚类算法获得的锚框更加符合炮孔检测的目标要求,同时考虑到炮孔独特的形状比例,重新定义距离算法,使得锚框长宽比参数更加契合真实框,从而在进行炮孔检测时可以得到更高的准确率。

### 1.3 轻量化炮孔智能检测模型

常规目标检测模型在文件大小和网络复杂性上存在局限性,需要大量存储和高算力支持。然而,智能装药车的作业场地通常为隧道或巷道,搭载高性能计算机的成本效益较低。因此,对炮孔检测模型进行轻量化处理,摆脱对大存储和高算力的依赖是必要的。为了解决炮孔图片中炮孔较小和高质量图像的问题,笔者设计了 MCIW-2 轻量化炮孔智能检测模型。该模型采用单阶段目标检测结构,由主干 (Backbone)、颈部 (Neck) 和头部 (Head) 3 部分组成。其中 Backbone 层主要负责特征的提取; Neck 层负责对提取的特征进行融合; Head 层负责输出模型的预测结果<sup>[18]</sup>。MCIW-2 轻量化炮孔智能检测模型可在智能装药车上装配部署、识别精度高且检测速度快,其整体结构如图 3 所示。

网络, MobileNetv3-Small 轻量化网络模型在降低参数计算量的同时仍然可以保证具有较高的特征提取能力。对比 MobileNet 的前 2 个版本,在 MobileNetv3-Small 中包含特有的 bneck 结构,更新了逆残差结构,具有深度可分离卷积,引入了轻量级的通道注意力机制 SE 模块,使用了 NAS 搜索参数的技术,同时对耗时较大的网络层进行了重新改进,设计了 H-Swish 激活函数, H-Swish 函数定义为

$$\text{ReLU6}(z) = \min [\max (z, 0), 6] \quad (3)$$

$$\text{H-Swish}(z) = z \frac{\text{ReLU6}(z+3)}{6} \quad (4)$$

其中,  $z$  为输入数据; ReLU6 为 ReLU 激活函数的变体。

笔者基于 MobileNetv3-Small 轻量化网络设计了炮孔智能检测模型 MCIW-2 的 Backbone 的主干网络, 表 1 为 MobileNetv3-Small 的网络结构参数。

表 1 MobileNetv3-Small 结构参数

Table 1 Structure parameters of MobileNetv3-Small

网络层	输入通道数	输入大小	激活函数	步长
Conv2d, 3×3	3	224×224	HS	2
bneck, 3×3	16	112×112	RE	2
bneck, 3×3	16	56×56	RE	2
bneck, 3×3	24	28×28	RE	1
bneck, 5×5	24	28×28	HS	2
(bneck, 5×5)×3	40	14×14	HS	1
bneck, 5×5	48	14×14	HS	1
bneck, 5×5	48	14×14	HS	2
(bneck, 5×5)×2	96	7×7	HS	1
Conv2d, 1×1	96	7×7	HS	1
Avg Pooling, 7×7	576	7×7	—	1
Conv2d, 1×1, NBN	576	1×1	HS	1
Conv2d, 1×1, NBN	1024	1×1	—	1

注: HS为H-Swish激活函数; RE为ReLU激活函数; NBN为在 Conv2d中不使用BN结构。

MCIW-2 模型在 MobileNetv3-Small 基础网络结




图 4 SPP 模块与 SPPCSP 模块的对比

Fig.4 Comparison of SPP module and SPPCSP module

### 1.3.3 Head 网络

检测头的数量直接影响模型的整体性能, 使用较少的检测头可以减少模型参数和提高检测速度, 设计合理的网络结构和与之相匹配的检测头数量可以使模型达到最佳的性能。笔者在设计轻量化炮孔智能检测模型时, 为了得到综合性能最好的轻量化炮孔智能检测模型使用了检测头数量不同的设计结构, 通过不断优化网络结构, 最终使用 2 个检测头就可以使轻量化炮孔智能检测模型达到最优性能。

构上进行精简, 构建了多个 bneck 结构与注意力机制 CBAM 网络融合的组合方式, 获得综合性能最佳的轻量化炮孔智能检测模型。表 2 为炮孔智能检测模型 MCIW-2 的主干网络结构参数。

表 2 炮孔智能检测模型主干网络结构参数

Table 2 Structure parameters of blasthole intelligent detection model backbone network

网络层	输入通道数	输入大小	激活函数	步长
Conv2d, 3×3	3	640×640	HS	2
bneck, 3×3	16	320×320	RE	2
CBAM	16	160×160	—	—
bneck, 5×5	16	160×160	HS	1
bneck, 5×5	40	160×160	HS	1
CBAM	96	160×160	—	—
bneck, 5×5	96	160×160	HS	2

### 1.3.2 Neck 网络

轻量化炮孔智能检测模型 MCIW-2 的 Neck 网络部分主要是对 Backbone 网络提取的特征进行融合。在 MCIW-2 模型中主要包含 SPPCSP 模块与 MCB 模块。SPPCSP 是 YOLOv7 中 Neck 的信息融合模块, 在 SPP 模块的基础上将浅层的网络进行 Concat 操作, 并与 SPP 模块之前的特征进行融合, 丰富了特征信息。如图 4 所示, SPP 模块与 SPPCSP 模块的对比。在 MCB 模块部分, 梯度传输的路径没有被改变, 通过多个模块的堆积扩大了特征的数量, 使用 expand、shuffle 和 merge cardinality 等策略实现在保证原始梯度路径不被破坏的前提下, 提高网络的学习能力。

### 1.3.4 CBAM 注意力机制

注意力机制的作用是对图像中重要的特征信息进行筛选聚焦, 抑制背景特征的影响, 从而提高分析能力的一种机制。CBAM 是由 WOO 等<sup>[24]</sup>提出的一种轻量化注意力模块, 该模块可以从通道和空间 2 个维度上进行注意力的添加, 通道和空间两个维度产生的注意力特征图信息与原始特征图进行乘积, 通过自适应特征得到最终的特征图。CBAM 注意力网络结构如图 5 所示。

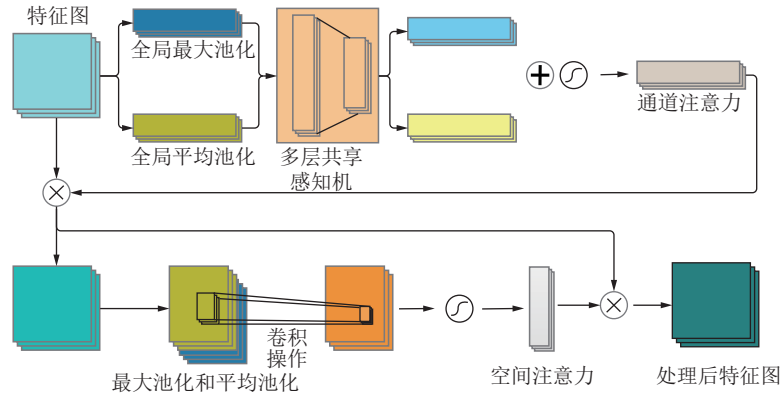


图5 CBAM注意力网络结构

Fig.5 CBAM attention network structure

CBAM的通道注意力机制是将输入的 $h \times w \times c$ 特征图,在空间维度上分别通过全局最大池化和全局平均池化2个分支,各得到一个 $1 \times 1 \times c$ 的特征图,然后将特征图分别输入到多层共享感知机MLP(Multi-Layer Perceptron, MLP)中进行特征的学习,最后将MLP的输出特征进行加和操作与Sigmoid激活函数处理,得到最终的通道注意力特征。

CBAM的空间注意力机制是将通道注意力模块的输出作为输入,首先通过基于通道的最大池化和平均池化,获得2个大小为 $h \times w \times 1$ 的特征图,然后将2个特征图在通道维度上进行拼接操作,得到大小为 $h \times w \times 2$ 的特征图,接着通过卷积操作,将特征图降维为 $h \times w \times 1$ ,最后通过Sigmoid激活函数处理,得到最终的空间注意力特征。

#### 1.4 IoU损失函数的优化

IoU损失函数可以反映出真实目标边框与预测边框之间的匹配程度,选择一个合适的IoU损失函数对于炮孔的快速高效检测十分重要。YOLOv7中默认使用的损失函数为 $C_{IoU}$ ,该损失函数考虑了真实边框与预测边框之间的重叠面积、中心点距离以及边框的长宽比,通过该损失函数可以得到更加符合真实框的预测框。 $C_{IoU}$ 损失函数的定义为

$$L_{C_{IoU}} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (5)$$

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

$$v = \frac{4}{\pi^2} \left[ \arctan\left(\frac{w^{gt}}{h^{gt}}\right) - \arctan\left(\frac{w}{h}\right) \right]^2 \quad (7)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (8)$$

式中, $A$ 为预测框的面积; $B$ 为真实框的面积; $\alpha$ 为权重系数; $v$ 为长宽比之间的相似性; $w$ 和 $h$ 分别为预测框的

宽度和高度; $w^{gt}$ 、 $h^{gt}$ 分别为真实框的宽度和高度; $L_{C_{IoU}}$ 为最终的 $C_{IoU}$ 损失函数; $b$ 、 $b^{gt}$ 分别为预测框与真实框的中心属性值; $\rho$ 为预测框与真实框2个中心点的欧氏距离; $c$ 为能够同时包含预测框和真实框的最小闭包区域的对角线距离。

现有大多数损失函数 $G_{IoU}$ 、 $D_{IoU}$ 以及 $C_{IoU}$ 都考虑了与检测边框相关的影响因子,并通过添加惩罚项来解决训练过程中边框之间重叠区域宽度无法更新的问题,这种机制会对低质量的图片造成惩罚过重的结果。隧道中由于光线环境较差,拍摄的炮孔图片中会含有大量的质量较低的图片,以往的损失函数通过惩罚因子的方式会增加对低质量图片的惩罚程度,这样会使得炮孔图片的泛化性大大降低, $W_{IoU}$ <sup>[25]</sup>通过动态非单调的聚焦机制,在降低对高质量锚框竞争的同时也减小了对低质量样本的损害,从而解决了高质量和低质量样本之间边框回归的平衡问题,因此,选择使用 $W_{IoU}$ 来作为本研究设计的炮孔检测模型损失函数是一个不错的选择。 $W_{IoU}$ 的定义为

$$L_{W_{IoU}} = R_{W_{IoU}} L_{IoU} \quad (9)$$

$$R_{W_{IoU}} = \exp \left[ \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right] \quad (10)$$

$$L_{IoU} = 1 - IoU \quad (11)$$

式中, $(x, y)$ 、 $(x_{gt}, y_{gt})$ 为预测框与真实框中心点坐标的属性值; $W_g$ 、 $H_g$ 为最小的边框的宽度和高度;上标\*为将 $W_g$ 和 $H_g$ 从计算图中分离出来,以防止 $R_{W_{IoU}}$ 影响梯度的收敛。

## 2 模型训练与结果分析

### 2.1 数据集

笔者所使用的数据为隧道工程掘进作业中工作面上采集的炮孔图片。在图片数据采集过程中,对不

同角度、不同光线环境的工作面进行了拍摄,通过对不合格图像的筛选,整理汇总原始炮孔图片数据总量为 1 979。基于炮孔图片最小中心距离切割法对图片数据集进行数据扩充,最终用于实验的数据总量为 9 895。在对模型进行试验时,按 8 : 2 的比例对训练集与测试集进行随机划分。

2.2 轻量化炮孔智能检测流程

笔者所构建轻量化炮孔智能检测实现流程具体描述如下:首先,使用相机在隧道中采集炮孔图片;其次,对采集的图片进行处理以满足模型训练要求;再次,使用经过处理的图片对轻量化炮孔智能检测模型进行训练;最后,固定模型参数并将其封装为 NVIDIA 的 TensorRT,在嵌入式环境上部署经过训练的模型对待检测的新的炮孔图片进行炮孔检测,并获得炮孔位置信息。具体流程步骤如图 6 所示。

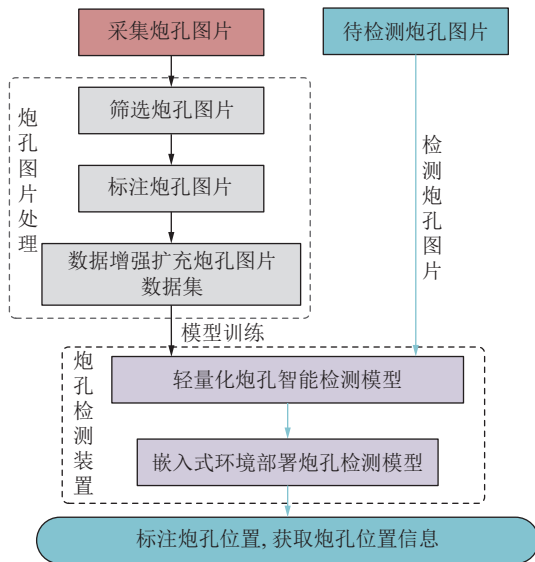


图 6 轻量化炮孔智能检测流程

Fig.6 Lightweight blasthole intelligent detection process

2.3 试验设备与配置

试验设备为 1 台 Windows 10 专业工作站版 64 位操作系统,内存大小为 128 G,CPU 为 Intel(R) Xeon(R) CPU E5-2650 v4 @ 2.20 GHz,训练过程中采用 GPU 加速设备为 NVIDIA GeForce RTX 2080 Ti,嵌入式设备为英伟达 NVIDIA Jetson Xavier NX。

2.4 试验评价指标

为了对比试验模型在不同条件下的性能,定量的分析炮孔检测效果,从平均精确度 (Mean Average Precision,  $P_{mA}$ ) 和检测速度、召回率 ( $R$ ) 曲线和模型文件大小 4 个方面来分析模型的整体表现。计算公式为

$$P = \frac{T_{TP}}{T_{TP} + F_{FP}} \times 100\% \quad (12)$$

$$R = \frac{T_{TP}}{T_{TP} + F_{FN}} \times 100\% \quad (13)$$

$$P_{mA} = \int_0^1 P(R) dR \quad (14)$$

$$S_{FP} = \frac{1}{t} \quad (15)$$

其中,  $T_{TP}$  为正确的预测出了炮孔;  $F_{FP}$  为错误的预测结果,不是炮孔的位置作为了炮孔;  $F_{FN}$  为把炮孔图片识别错误,真实炮孔没有检测出来;  $P$  为精确度;  $P_{mA}$  为平均精度;  $t$  为检测时间;检测速度用每秒帧数 (Frames Per Second,  $S_{FP}$ ) 来评价。

2.5 试验结果及分析

为了验证模型中各模块的效果,通过控制模块变量的方式进行对比,在 YOLOv7 基准模型的基础上分别对 4 个模块进行了控制引入消融实验,包括 MobileNetv3(MN3) 替换主干网络、改进的锚框 (Improved Anchor, IA) 长宽比参数、引入注意力 CBAM 模块和替换损失函数 ( $W_{IoU}$ )。表 3 为消融实验的结果。

表 3 消融实验结果

Table 3 Ablation experimental results

MN3	IA	CBAM	$W_{IoU}$	平均精确率/%	召回率/%	模型文件大小/Mb	检测速度/fps
				94.98	92.15	11.6	52.08
√				92.06	88.73	8.22	39.71
√	√			93.54	91.96	8.22	39.89
√	√	√		94.49	92.03	8.22	40.34
√	√	√	√	95.21	92.29	8.22	40.71

表 3 消融实验的结果表明 MN3、IA、CBAM 和  $W_{IoU}$  模块均对提高模型平均准确率和检测速度有积极的作用。通过控制模块的引入,精度的提升达到了

近 4%。同时,模型检测速度提高了近 1%。

为了构建最佳性能的智能炮孔检测模型,笔者探索了检测头数目对检测效果影响。笔者构建 MCIW-2、

MCIW-3 和 MCIW-4 模型, 分别设置检测头数目为 2、3 和 4 个。实验结果表明 2 个检测头的网络结构的平均精度最高, 为 96.18%; 3 个检测头的网络结构的平均精度为 96.14%; 4 个检测头的网络结构的平均精度最低, 为 95.91%。多检测头对比试验结果见表 4。

表 4 多检测头试验对比结果

模型名称	平均精确率/%	召回率/%	模型文件大小/Mb	检测速度/fps
MCIW-2	96.18	93.07	2.80	58.72
MCIW-3	96.14	93.45	7.27	48.31
MCIW-4	95.91	93.03	7.84	40.03

根据表 4 的实验结果, 可以得出结论: 炮孔检测模型的精度与检测头数量出现负相关。2 个检测头的模型不仅表现出更高的检测精确率, 并且在检测速度和模型文件大小上也有明显优势。在深度学习技术中, 模型结构的有效学习并不与模型复杂性成线性相关。复杂度高的模型会产生过拟合学习。模型中用于提取特征的主要结构为卷积神经网络, 其特点为浅层网络可以捕获更多的颜色、纹理等局部信息, 而深层网络获得的是图像的整体信息和语义信息<sup>[26]</sup>。对于炮孔检测任务, 炮孔在整个图片中属于小目标且具有相对单一的特征, 浅层的网络完全可以获得足够多的炮孔特征细节, 使用更多的检测头获取到的是炮孔图片粗粒度的特征信息, 导致部分锚框在回归时不精确甚至错误, 从而降低了最终的炮孔检测精度。因此, 基于奥卡姆剃刀原理的考量, 采用 2 个检测头的炮孔检测模型可以更好的满足炮孔检测任务的要求。

笔者将轻量化炮孔智能检测模型 MCIW-2 在与经典目标识别 YOLO 系列模型进行比较。实验结果表明 MCIW-2 在炮孔识别任务中表现出优异的性能。表 5 为模型 MCIW-2 与 YOLO 系列对比结果。

通过对比表 5, 可以发现 MCIW-2 在显著减小模型文件大小的同时, 仍能保持较高的识别精度和较快的检测速度。平均精确率达到了 96.18%, 模型文件大小仅为 2.80 Mb。相较于 YOLO 系列中模型文件最小的 YOLOv7 基准模型, 模型文件大小减小了 75.86%。因此, 使用笔者设计的轻量化炮孔识别算法在智能装药车的炮孔识别中具有显著的优势。

表 5 模型 MCIW-2 与 YOLO 系列对比结果

Table 5 Comparison results of model MCIW-2 and YOLO series

模型名称	平均精确率/%	召回率/%	模型文件大小/Mb	检测速度/fps
YOLOv5	93.25	90.24	14.6	43.25
YOLOv7	94.98	92.15	11.6	52.08
YOLOv8	94.06	88.87	21.4	35.61
MCIW-2	96.18	93.07	2.8	58.72

为了验证 MCIW-2 模型对炮孔轮廓的标注效果, 笔者选取了不同环境下的炮孔图片进行测试验证。通过图 7 可以直观地评估 MCIW-2 模型的位置标注效果。其中, 图 7(b) 为 YOLOv7 中的炮孔标注结果, 红色方框仅标记了一个小细线, 无法准确标定炮孔轮廓, 而图 7(c) 为使用自适应锚框参数的 MCIW-2 模型的炮孔标注结果, 红色方框中的标注框准确地标定了炮孔轮廓的位置。

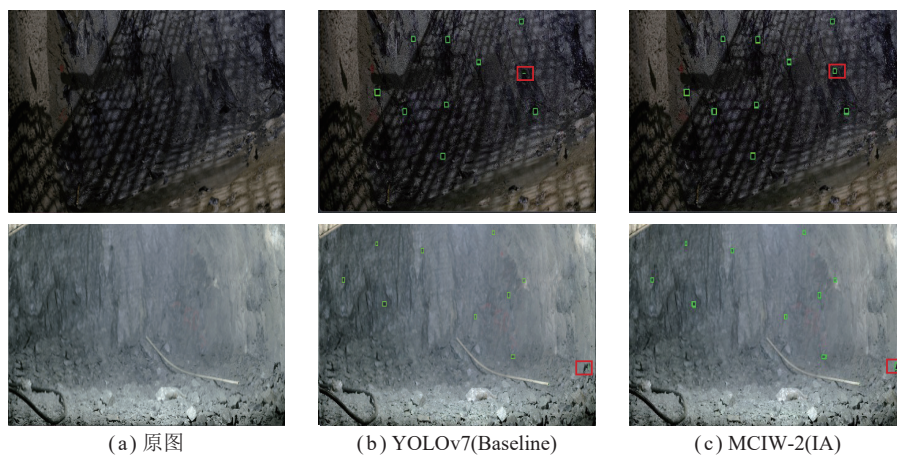


图 7 使用自适应锚框参数的标注效果

Fig.7 Annotated renderings using adaptive anchor frame parameters

在微小炮孔识别方面, 笔者将 MCIW-2 模型与 YOLO 系列中表现最佳的 YOLOv7 模型的炮孔检测结果图进行对比, 可以发现图 8(c) 中 MCIW-2 模型能

够准确识别出红色方框中的微小炮孔, 而图 8(b) 中 YOLOv7 模型则未能识别出相同位置的炮孔。这表明 MCIW-2 模型可以有效获取炮孔图片中微小的炮

孔细节特征,实现对较小炮孔的准确识别,从而降低了炮孔识别的漏检率。




图 8 微小炮孔检测结果对比

Fig.8 Comparison of micro hole test results

### 2.6 工程应用

轻量化炮孔智能检测 MCIW-2 模型部署完成后,将其应用于隧道工作面的现场视频,进行炮孔检测的应用测试。视频拍摄于国道 109 新线高速项目的小龙门隧道工作面,采用数码相机拍摄,视频格式为 MP4。模型 MCIW-2 的应用测试炮孔检测效果,如图 9 所示。




图 9 模型 MCIW-2 炮孔检测应用测试效果

Fig.9 Application and testing effect of model MCIW-2 blasthole detection

如图 9 所示,视频左侧窗口为现场拍摄内容,右侧窗口为标有炮孔标注框的炮孔识别结果。当视频的某一帧含有炮孔时,将会检测出这一帧视频中的所有炮孔,并用黄色方框标记出炮孔位置,获取位置信

息。MCIW-2 模型在炮孔检测方面整体表现性能更好,适合应用于隧道(巷道)工作面的炮孔检测。

### 3 结 论

(1) 自适应锚框聚类算法可以使模型针对炮孔图像特征生成合适的锚框参数,进而提高模型识别效果,获得规范的炮孔标注结果。

(2) CBAM 注意力机制可以从通道和空间 2 个维度提升模型的学习能力; $W_{IoU}$  损失函数可以进一步训练模型的动态非单调聚焦机制,提高对低质量的炮孔图片的识别能力。2 者共同用于构建炮孔智能检测模型,最终的模型平均精确率达到了 96.18%。

(3) 检测头的数量、网络模型的深度要与炮孔图像的特征相匹配,才能达到较好的识别效果,过于复杂的网络结构易于产生过拟合。2 个检测头的 MCIW-2 模型在 Head 模块中的结构最简单,却可以在识别任务中达到更高的精准度,并且在轻量化部署中也占据优势。在工作面现场视频测试中 MCIW-2 模型取得了较好的检测效果,验证了模型的可行性和实用性。

### 参考文献(References):

[1] 王国法, 赵国瑞, 任怀伟. 智慧煤矿与智能化开采关键核心技术分析[J]. 煤炭学报, 2019, 44(1): 34-41.  
 WANG Guofa, ZHAO Guorui, REN Huaiwei. Analysis on key technologies of intelligent coal mine and intelligent mining[J]. Journal of China Coal Society, 2019, 44(1): 34-41.

- [2] BONCHIS A, DUFF E, ROBERTS J, et al. Robotic explosive charging in mining and construction applications[J]. *IEEE Transactions on Automation Science & Engineering*, 2014, 11(1): 245–250.
- [3] 李鑫, 查正清, 臧怀壮, 等. 地下矿用乳化炸药混装车的安全设计与现场应用[J]. *工程爆破*, 2015, 21(6): 47–50.  
LI Xin, ZHA Zhengqing, ZANG Huaizhuang, et al. Safety design and application of emulsion explosive charging truck for underground mine[J]. *Engineering Blasting*, 2015, 21(6): 47–50.
- [4] 张庆贺, 陈晨, 袁亮, 等. 基于 DIC 和 YOLO 算法的复杂裂隙岩石破坏过程动态裂隙早期智能识别[J]. *煤炭学报*, 2022, 47(3): 1208–1219.  
ZHANG Qinghe, CHEN Chen, YUAN Liang, et al. Early and intelligent recognition of dynamic cracks during damage of complex fractured rock masses based on DIC and YOLO algorithms[J]. *Journal of China Coal Society*, 2022, 47(3): 1208–1219.
- [5] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition(CVPR 2014), 23–28 June 2014, Columbus, Ohio. Institute of Electrical and Electronics Engineers, 2014: 580–587.
- [6] GIRSHICK R. Fast R-CNN[C]//Proceedings of the 2015 IEEE international conference on computer vision (ICCV)Santiago. IEEE, 2015: 1440–1448.
- [7] REN S, HE K, 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.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//IEEE Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 779–788.
- [9] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2017: 6517–6525.
- [10] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. *arXiv*, 2018: 1804.02767.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[J]. *arXiv*, 2020: 2004.10934.
- [12] LI Chuyi, LI Lulu, JIANG Hongliang, et al. YOLOv6: A single-stage object detection framework for industrial applications[J]. *arXiv*, 2022: 2209.02976.
- [13] WANG C Y, BOCHKOVSKIY A, LIAO H. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. *arXiv*, 2022: 2207.02696.
- [14] LIU Wei, AUGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]// European Conference on Computer Vision. Springer, Cham, 2016: 21–37.
- [15] 阮顺领, 李少博, 卢才武, 等. 多尺度特征融合的露天矿区道路障碍物检测[J]. *煤炭学报*, 2021, 46(S2): 1170–1179.  
RUAN Shunling, LI Shaobo, LU Caiwu, et al. Road negative obstacle detection in open-pit mines based on multi scale feature fusion[J]. *Journal of China Coal Society*, 2021, 46(S2): 1170–1179.
- [16] 张万志. 岩质隧道炮孔图像识别算法及光面爆破参数优化研究[D]. 济南: 山东大学, 2019.  
ZHANG Wan zhi. Research on blasthole image recognition algorithms and optimization of smooth blasting parameters of rock tunnel[D]. Jinan: Shandong University, 2019.
- [17] 张也. 智能炸药充填机器人炮孔识别与可行区域规划相关技术研究[D]. 鞍山: 辽宁科技大学, 2020.  
ZHANG Ye. Research on blast hole identification of intelligent explosive filling robot and passable area planning[D]. Anshan: University of Science and Technology Liaoning, 2020.
- [18] 李明, 鹿朋, 朱美强, 等. 基于改进 YOLO-tiny 的闸板阀开度检测[J]. *煤炭学报*, 2021, 46(S2): 1180–1190.  
LI Ming, LU Peng, ZHU Meiqiang, et al. Opening degree detection of gate valve based on improved YOLO-tiny[J]. *Journal of China Coal Society*, 2021, 46(S2): 1180–1190.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84–90.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas: IEEE, 2016: 770–778.
- [21] 程德强, 徐进洋, 寇旗旗, 等. 融合残差信息轻量级网络的运煤皮带异物分类[J]. *煤炭学报*, 2022, 47(3): 1361–1369.  
CHENG Deqiang, XU Jinyang, KOU Qiqi, et al. Lightweight network based on residual information for foreign body classification on coal conveyor belt[J]. *Journal of China Coal Society*, 2022, 47(3): 1361–1369.
- [22] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. *arXiv*, 2017: 1704.04861.
- [23] HOWARD A, SANDLER M, CHEN B, et al. Searching for mobileNetV3[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 1314–1324.
- [24] WOO S, PARK J, LEE JY, et al. CBAM: Convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 3–19.
- [25] TONG Zanjia, CHEN Yuhang, XU Zewei, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. *arXiv*, 2023: 2301.10051.
- [26] 赵菲, 邓英捷. 融合多异构滤波器的轻型弱小目标检测网络[J]. *光学学报*, 2023, 43(9): 153–164.  
ZHAO Fei, DENG Yingjie. Light dim small target detection network with multi-heterogeneous filters[J]. *Acta Optica Sinica*, 2023, 43(9): 153–164.