

葛淑伟,张永茜,秦嘉欣,等. 基于优化SSD-MobileNetV2的煤矿井下锚孔检测方法[J]. 采矿与岩层控制工程学报, 2023, 5(2): 026525.

GE Shuwei, ZHANG Yongqian, QIN Jiabin, et al. Rock bolt borehole detection method for underground coal mines based on optimized SSD-MobileNetV2[J]. Journal of Mining and Strata Control Engineering, 2023, 5(2): 026525.

基于优化SSD-MobileNetV2的煤矿井下锚孔检测方法

葛淑伟,张永茜,秦嘉欣,李雪,王晓

(中国矿业大学(北京)机电与信息工程学院,北京 100083)

摘要:为进一步提高煤矿井下打锚技术的自动化水平和安全性,提出了煤矿井下钢带锚孔自动检测方法。选取兼具检测精度与速度的SSD算法作为检测网络,以轻量化MobileNetV2为骨干特征提取网络建立了锚孔检测模型。针对煤矿井下钢带锚孔目标小、不易检测的问题,优化了先验框的设置,使得先验框进一步与有效感受野匹配,提高识别精度。该锚孔检测模型对于自建数据集中的锚孔目标识别准确率为94.24%,AP达94.08%,取得了较好的检测效果;检测速度可达84.73帧/s;模型大小仅为14.3 MB。模型经TensorRT优化并部署于NVIDIA Jetson Xavier NX硬件平台上,验证了模型的可应用性。

关键词:煤矿自动化;SSD算法;锚孔检测;深度神经网络

中图分类号:TD67;TP391.41 **文献标志码:**A **文章编号:**2096-7187(2023)02-6525-09

Rock bolt borehole detection method for underground coal mines based on optimized SSD-MobileNetV2

GE Shuwei, ZHANG Yongqian, QIN Jiabin, LI Xue, WANG Xiao

(School of Mechanical Electronic and Information Engineering, China University of Mining and Technology(Beijing), Beijing 100083, China)

Abstract:To enhance the automation level and safety of anchor drilling technology in underground coal mines, a method for automatic detection of steel strip rock bolt boreholes is proposed. The detection network utilizes the SSD algorithm, balancing detection accuracy and speed, and a lightweight MobileNetV2 backbone feature extraction network is used to establish the rock bolt borehole detection model. To address the issue of small rock bolt borehole targets in underground coal mines, the prior box is optimized to match the effective receptive field, improving recognition accuracy. The rock bolt borehole detection model achieves 94.24% accuracy and 94.08% AP for rock bolt borehole target identification in the self-built dataset, with a detection speed of 84.73FPS and a model size of only 14.3 MB. The model is optimized using TensorRT and deployed on the NVIDIA Jetson Xavier NX hardware platform to demonstrate its practicality.

Key words: coal mine automation; SSD algorithm; rock bolt borehole; deep neural networks

智能化开采是煤矿生产发展的必然趋势^[1-3]。下巷道。为保持巷道畅通及周围围岩的稳定,需要我国煤矿生产以地下开采为主,需要构建大量的井对其进行锚杆支护^[4-5]。传统的锚杆支护工作以人

收稿日期:2022-07-24

修回日期:2022-08-25

责任编辑:施红霞

作者简介:葛淑伟(1996—),男,河北张家口人,硕士研究生,主要从事深度学习、计算机视觉、目标检测等方面的研究工作。E-mail:ShuweiGe@outlook.com

工为主,其存在两方面的问题:一是打锚孔需要耗费大量的人力成本,整体工作效率较低;二是煤矿采掘、支护工作面附近存在较高的安全隐患,特别是在未完成支护的巷道中,工人现场操作危险性较高。

自动化锚杆支护是煤矿智能化开采的重要组成部分,而实现打锚的自动化,锚孔的自动检测是主要工作之一。因煤矿井下地质因素复杂,往往在锚杆支护前需铺设支护钢带,钢带预留锚杆穿过的孔眼,大大增加了自动锚孔定位的难度,传统方法难以解决锚孔的精准定位,笔者拟采用深度学习技术研究煤矿井下钢带锚孔的精确检测。

基于深度学习的目标检测方法主要分为2大类: SPP-Net^[6], Fast R-CNN^[7], Faster R-CNN, R-FCN^[8]等属于基于候选区域的两阶段(Two Stage)目标检测算法; YOLO^[9], SSD等属于基于回归的一阶段(One Stage)目标检测算法。一阶段检测算法直接得到目标的类别概率和位置坐标值,检测速度较快^[10]。

近年来,基于深度学习的视觉检测技术取得了较大的发展。贾可心^[11]等提出基于Xception深度可分离卷积的SSD改进模型,进行了海面小目标检测; 杨侨^[12]等将SSD算法骨干网络由VGG-16替换为ResNet50,并引入注意力机制,改善了对小目标工件的检测效果; 丁飞^[13]等将轻量级GhostNet与YOLOv4结合用于遥感图像中建筑物的检测; 杜琥龙^[14]等将轻量级MobileNet网络与SSD检测算法结合,用于驾驶员分心行为检测。在煤矿相关应用中,苏钰桐^[15]等使用YOLOv3算法建立了目标检测模型,用于识别煤岩钻孔图像中的裂隙; 孙传猛^[16]等利用改进YOLOv3融合了三次样条插值识别煤岩界面; 张翼翔^[17]等构建了基于CenterNet-GhostNet检测网络的选煤厂危险区域人员检测系统,对人员目标取得了较好的检测效果。

笔者提出一种基于优化SSD-MobileNetV2深度学习的钢带锚孔视觉检测方法,为自动锚杆支护提供新的技术手段。

1 锚孔检测问题

根据国际组织SPIE的定义,目标面积小于整幅图像面积12%的物体被定义为小目标。图1中锚孔目标占整幅图像的面积小于12%,属于小目标。对

小目标检测的困难之处在于其覆盖面积小,包含的语义信息少,检测效果不理想^[18]。



图1 煤矿井下钢带锚孔示例

Fig. 1 Example of steel belt anchor holes in coal mine

煤矿井下粉尘多,照度不均匀,是一种典型的非结构化环境。环境背景以煤为主,加之照度低,图像中锚孔边界和钢带之间区分度低,导致采集到的图像普遍画质较差,且图片同质化严重。因此,基于深度学习的锚孔检测方法需要解决以下4个难点:

- (1) 采集的图像亮度低、画质弱,会影响检测效果,识别钢带孔前需进行图像预处理;
- (2) 同质化图片构成的训练集易导致模型过拟合,泛化能力减弱,需解决同质化图像给模型训练带来的困难;
- (3) 实时性要求高,算法要尽可能提高检测速度;
- (4) 模型需规模较小,以便于部署在自动锚杆机的嵌入式装置上。

传统目标检测方法是建立一系列的边界框(Bounding Box),采样每个框的像素点或特征,并施加一个高质量分类器网络,如Faster R-CNN^[19],检测效果较好,但计算量巨大,且检测速度较慢,对于嵌入式系统而言难以胜任。

SSD(Single Shot Multibox Detector)网络在检测精度与速度上具有较好的平衡性,其完全去除了候选区域生成和随后的特征再筛选的过程,把所有的计算封装在一个网络里面,在保证准确性的同时,速度也有保障,适用于工业场景下的部署应用。因此,笔者以SSD算法为基础,建立煤矿井下锚孔小目标检测模型。

2 锚孔检测模型

2.1 SSD网络

SSD算法^[20]发表于ECCV-2016,是继Faster R-

CNN和YOLO算法之后又一个杰出的目标检测算法。标准SSD网络架构如图2所示,它采用VGG-16(Visual Geometry Group Network-16)^[21]作为骨干网络,将其末端全连接层删除,骨干网络后接一系列的卷积层和池化层,用于提取目标特征。对于目标尺度变化的问题,SSD通过一个单网络分别在6个不

同尺度的特征图上进行检测,以达到模拟将图片预处理为不同尺寸的效果。但是,SSD的金字塔特征分层(Pyramdial Feature Hierarchy)对小目标的召回率一般,没有明显优于Faster R-CNN,且以VGG-16作为骨干网络的SSD模型较大,不适合煤矿井下锚孔自动识别的要求,需要进行改进。

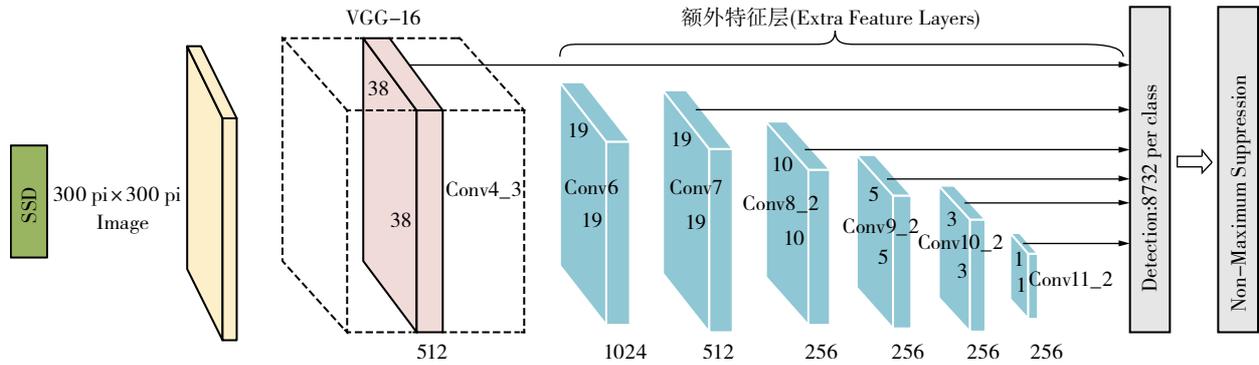


图2 标准SSD网络结构示意图

Fig. 2 Standard SSD network structure

2.2 MobileNetV2

MobileNetV2^[22]是谷歌团队提出的应用在嵌入式设备中的轻量级CNN网络,其主要特点是采用了深度可分离卷积和倒残差结构(Inverted Residual)。

深度可分离卷积是一种轻量化的卷积方式, MobileNetV2使用轻量级深度可分离卷积过滤中间扩展层的特征,将逐通道卷积和逐点 1×1 卷积2种卷积方式相结合,计算量大大减少。以采用 3×3 卷积核为例,深度可分离卷积计算量为标准卷积的 $1/9$ 。

倒残差结构如图3所示,网络首先通过 1×1 卷积扩张通道数,将低维压缩表示扩展到高维,随后使用轻量级深度卷积做过滤,再使用 1×1 卷积减少通道数,最后用线性瓶颈结构(Linear Bottleneck)将特征投影回低维表示。

对于锚孔的识别任务,对高度同质化的锚孔图像采用线性瓶颈结构,不仅保持了模型的代表能力,同时在移除短层中的非线性后提升了网络的性能。另外,选用线性映射,可减少特征的损失,最大限度地保留锚孔特征。

2.3 锚孔识别模型

笔者以MobileNetV2为特征提取网络,SSD为多尺度检测网络构建钢带锚孔检测模型。模型输入的图片尺寸为 $300 \text{ pi} \times 300 \text{ pi}$ 。检测时首先经过MobileNetV2提取多尺度特征,然后在6个不同尺度

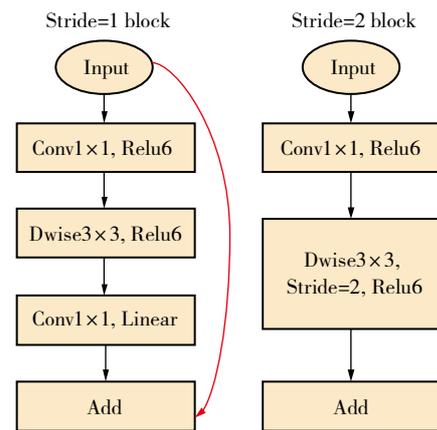


图3 MobileNetV2的倒残差结构

Fig. 3 Inverted residual structure of MobileNetV2

上预测结果,最终经过检测器融合,输出检测结果。模型结构如图4所示,图中依次为输入层、普通卷积层、Stride为1,2时的Inverted Residual模块,红色线为Stride=1且输入与输出矩阵Shape相同时的Shortcut连接。限于版面,中间相似的Inverted Residual模块未画出。

2.4 先验框匹配及优化调整

采用SSD网络进行目标识别,训练输入待检测的锚孔图片和对应的真实框(GT Boxes),对每个位置输出一系列离散的先验框(Default Box)。这些先验框具有不同的尺寸和宽高比,每个都会输出预测的锚孔形状偏差和得分,通过打分和调整使先验框更好地匹配目标。

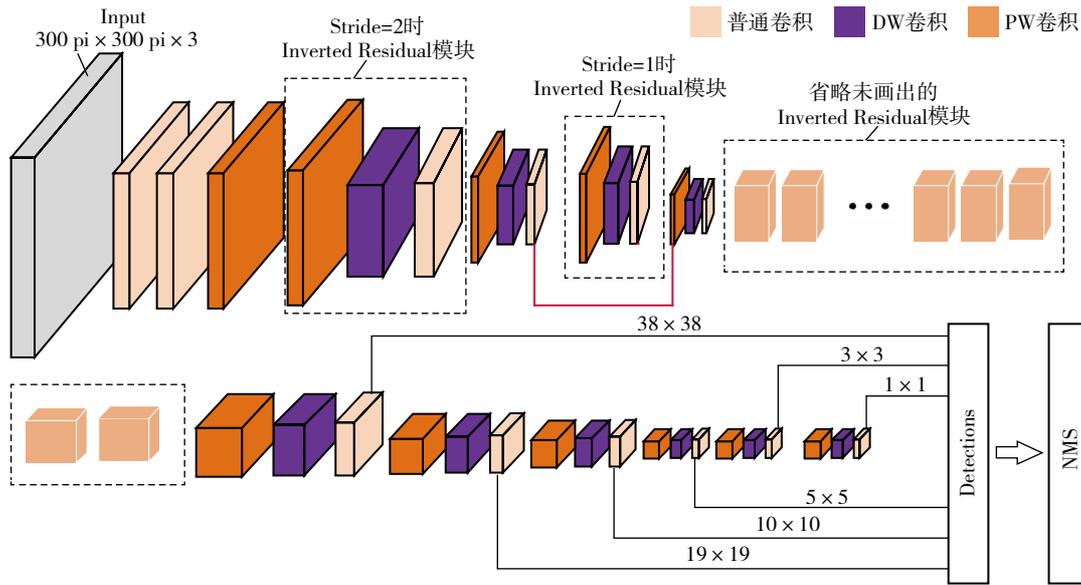


图4 SSD-MobileNetV2模型结构示意图

Fig. 4 Structure of the SSD-MobileNetV2 model

假定用于锚孔检测的特征图个数为 m , 设置一系列具有不同宽高比的先验框, 先验框相对于原图的比例尺度记作 S_k , 先验框的宽高比记作 a_r , $a_r \in \{1, 2, 3, 1/2, 1/3\}$ 。

尺度计算公式为

$$S_k = S_{\min} + \frac{S_{\max} - S_{\min}}{m-1} (k-1) \quad k \in [1, m] \quad (1)$$

式中, S_k 为尺度; S_{\min} 为尺度最小值, 标准SSD中取0.2; S_{\max} 为尺度最大值, 标准SSD中取0.9。

先验框的宽、高计算公式分别为

$$W = S_k \sqrt{a_r} \quad (2)$$

$$H = \frac{S_k}{\sqrt{a_r}} \quad (3)$$

特别地, 当 $a_r = 1$ 时, 增加1个先验框, 此时 $W = H = \sqrt{S_k S_{k+1}}$, 即保证特征图上的每个位置都有6个先验框。框的中心点计算公式为

$$\left(\frac{i+0.5}{|f_k|}, \frac{j+0.5}{|f_k|} \right) \quad i, j \in [0, |f_k|] \quad (4)$$

式中, $|f_k|$ 为第 k 个特征图的尺寸。

先验框匹配基于以下原则: 对于图像中每一个真实框, 找到与其交并比(Intersection over Union, IOU)最大的先验框, 该先验框标记为正样本。若一个先验框未与任何的真实框匹配, 则标记为负样本。对于剩下的未匹配的先验框, 若与真实框的IOU大于某个阈值(一般取0.5), 则该先验框也与真实值(Ground Truth)匹配, 标记为正样本, 最终未匹

配到真实框的均为负样本。

为使模型能够更好地检测到目标, 需要进一步调整先验框的分布和尺寸。数据集中的锚孔真实框尺寸为20~80 pi, 小目标居多, 为提高检测准确率, 特别调整浅层特征层的先验框大小。

考虑到巷道空间和自动锚杆机约束下允许的相机移动范围, 以及保证锚孔成像不会产生太大的畸变, 相机与钢带之间的距离限定在500~1000 mm, 因而锚孔图像的大小为20~80 pi。试验结果表明, $S_{\min} = 0.14$, $S_{\max} = 0.74$ 时, 先验框分布情况能够较好地匹配真实框, 达到最佳检测效果。经以上调整后的先验框分布情况见表1。

表1 特征层及对应先验框

Table1 Feature layer and corresponding prior box

特征层序号	特征层尺寸	先验框尺度	先验框宽高比	先验框数量
1	38 × 38	21	{1/2, 1, 2}	4
2	19 × 19	42	{1/3, 1/2, 1, 2, 3}	6
3	10 × 10	87	{1/3, 1/2, 1, 2, 3}	6
4	5 × 5	132	{1/3, 1/2, 1, 2, 3}	6
5	3 × 3	177	{1/2, 1, 2}	4
6	1 × 1	222	{1/2, 1, 2}	4

2.5 损失函数

自动打锚杆任务要求钢带锚孔位置的识别准确率高。待识别的钢带孔形状为准圆形, 目标较小, 识别出的钢带锚孔用矩形框标出, 笔者以矩形框的中心位置近似钢带锚孔的圆心。为获得锚孔的准确位置, 在损失函数中同时对锚孔类别和位置

建立约束。

位置损失用 $L_{loc}(x, l, g)$ 表示, 分类损失为 $L_{conf}(x, c)$, 以权重参数 α 调节这两部分的比重。建立的损失函数 L 计算公式为

$$L(x, c, l, g) = \frac{1}{N} [L_{conf}(x, c) + \alpha L_{loc}(x, l, g)] \quad (5)$$

式中, N 为预测框与真实框匹配的正样本个数; x 为表示当前预测框是否与真实框匹配, 匹配取1, 否则取0; c 为预测框置信度; l, g 分别为预测框和真实框的位置信息。

3 数据集与试验分析

3.1 锚孔数据集

3.1.1 钢带锚孔数据采集

由于笔者研究的是煤矿井下具体应用问题, 无公开数据集, 因此, 在模拟掘进工作面采集钢带锚孔图像时, 自行构建锚孔数据集。钢带上的锚孔一般均为圆形, 因此锚孔图像形状相似, 但受煤矿井下光照、背景等环境条件的影响以及拍摄位置的差

异, 得到的锚孔图像略有差异。笔者在搭建的模拟掘锚工作面进行拍摄时选取了不同照度、角度以及距离, 建立了原始图像数据集。

3.1.2 数据预处理

为提高模型的鲁棒性, 需对原始数据集进行数据增广、图像增强等预处理。采用的方法为随机改变图像的亮度、饱和度、对比度等参数。为进一步改善采集图像同质化程度高的问题, 对图片进行随机缩放、旋转、翻转、剪切等操作; 在图像中加入随机噪声使图像模糊, 以模拟井下真实环境中煤尘遮挡等问题。

原始采集图像实例如图1所示, 图像大小为 $1\ 920\ \text{pi} \times 1\ 200\ \text{pi}$, 图片画质较差, 亮度较低, 锚孔目标小且由于煤尘遮挡等因素, 锚孔目标难以与背景区分。数据预处理后的效果如图5所示, 图像大小为 $300\ \text{pi} \times 300\ \text{pi}$, 图像种类、形态、特点等更加丰富, 同质化程度显著降低, 亮度、对比度等均有明显改善, 锚孔目标清晰易于辨认, 更利于输入模型进行检测。

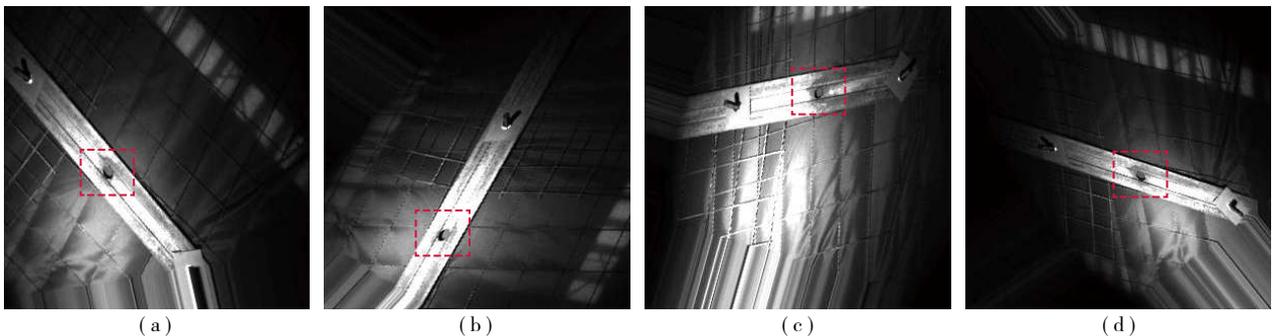


图5 数据增强效果

Fig. 5 Data enhancement effect

3.1.3 数据集标注

钢带锚孔数据集按照Pascal VOC2007^[23]的格式建立。标注采用开源工具LabelImg软件, 生成.xml格式的标签文件, 其中包含目标类别、真实框的位置等信息, 形成图片与标签文件一一对应的VOC2007格式钢带锚孔数据集。

该数据集共计2 000张图片。训练时, 将进一步在线增强, 继续扩大数据集, 以降低模型过拟合风险, 提高模型的鲁棒性。数据集的70%用于模型训练, 20%用于模型验证, 10%用于模型测试。

3.2 模型评价指标

模型的性能主要以模型的检测精度、检测速度和模型大小3个指标来评价。其中, 检测精度以测

试所得锚孔类AP(Average Precision)作为评价指标, AP由检测准确率 P (Precision) 和召回率 R (Recall) 计算得出。检测准确率和召回率的计算公式为

$$P = TP / (TP + FP) \quad (6)$$

$$R = TP / (TP + FN) \quad (7)$$

式中, TP 为正样本中预测为正的数量; FP 为负样本中预测为正的数; FN 为负样本中预测为负的数量。

3.3 试验环境配置与模型训练

试验平台配置如下: CPU为AMD Ryzen7 4800H with Radeon Graphics@2.9 GHz, 16 GB内存, Windows 11操作系统, 显卡型号为NVIDIA RTX 2060。运行环境Python的版本为3.6, Pytorch版本为1.6.0, CUDA

版本为11.2。

自建的锚孔数据集较小,因此,对模型的训练利用了迁移学习。训练时首先载入基于Imagenet数据集的预训练权重,设置200个训练轮次(Epoch),其中,前50个训练轮次冻结训练,批量大小(Batch-size)设置为32,后150个训练轮次解冻训练,批量大小保持为32。选择Adam优化算法更新权重,模型的最大学习率设置为 3×10^{-4} ,最小学习率设置为最大学习率的0.01。模型训练损失值随迭代次数变化趋势如图6所示,模型损失值随着训练轮次的增加逐渐下降,到100个训练轮次后已明显趋于收敛。

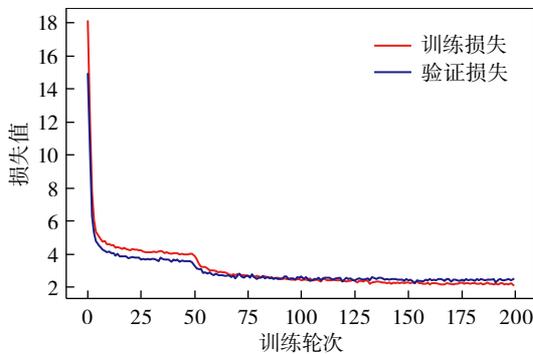


图6 模型训练损失值随迭代次数变化曲线

Fig. 6 Curves of the model training loss value changing with the epochs

3.4 模型检测效果

模型检测准确率如图7所示,阈值为0.5时,模型检测准确率达94.24%。准确率与召回率关系(PR)曲线如图8所示,锚孔类别的AP值达94.08%。

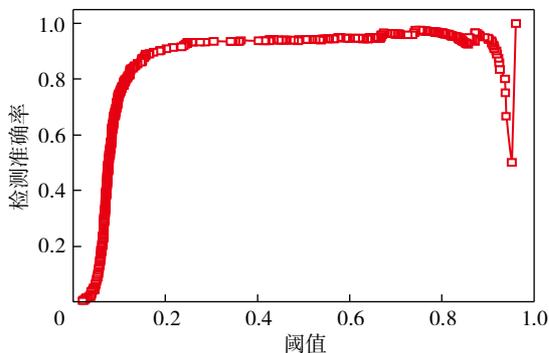


图7 模型检测准确率

Fig. 7 Detection accuracy of the model

图9,10分别为图片中只有单个锚孔和多个锚孔时的检测效果。图9(a)和10(a)为输入的原始图片,图9(b)和10(b)中的红色框及数值为模型检测标出的锚孔位置、目标类别与分类置信度。

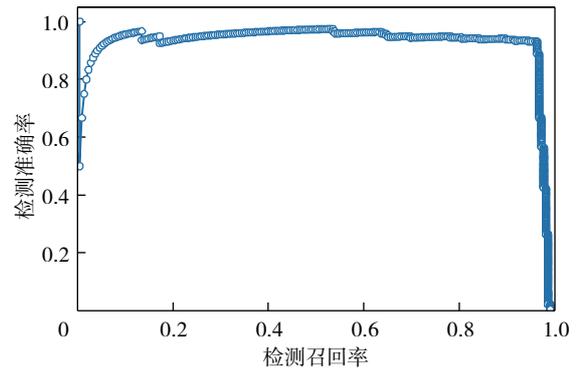


图8 模型PR曲线

Fig. 8 PR curve of the model



(a)



(b)

图9 图片中只有单个锚孔时的检测效果

Fig. 9 Detection effect with only one single anchor hole in the picture

经过多次测试,模型对于包含单个锚孔、多个锚孔的图片,均取得了较好的检测效果。对模型进行重复测试,AP值为93.80%~94.08%,模型性能稳定。为使模型能够实际用于锚孔检测,下一步还需对模型的稳定性进行研究。

3.5 对比试验与分析

为验证优化SSD-MobileNetV2模型在煤矿井下钢带锚孔检测中的可行性,在同一试验平台上对测试数据集进行检测。为了客观公正地进行对比,选择了不同主干网络的YOLO V4^[24]以及SSD与优化SSD-MobileNetV2模型进行比较。



图10 图片中有多个锚孔时检测的效果

Fig. 10 Detection effect with more than one anchor holes in the picture

3.5.1 检测效果对比试验

检测效果对比情况见表2。从检测精度上来看,本文模型准确率为94.24%,优于其他检测算法,

AP达到了94%以上。从检测速度上看,本文模型达到了84.73帧/s的检测速度,能够满足自动锚杆支护对检测实时性的要求。

表2 不同检测算法在锚孔数据集的检测精度及检测速度

Table 2 Detection accuracy and speed of different detection algorithms in anchor hole dataset

检测方法	骨干网络	输入尺寸/($\pi \times \pi$)	准确率 $P/\%$	AP/ $\%$	检测速度/(帧 \cdot s $^{-1}$)
YOLO V4	VGG-16	320 \times 320	92.79	94.66	49.31
YOLO V4	GhostNet	320 \times 320	92.96	94.80	36.89
YOLO V4	MobileNetV2	320 \times 320	93.67	94.65	53.33
SSD	VGG-16	300 \times 300	90.91	94.61	57.60
SSD-MobileNetV2(本文模型)		300 \times 300	94.24	94.08	84.73

3.5.2 模型规模对比

不同检测算法的模型大小统计见表3。模型大小由训练所得的模型的权重文件的大小表示,权重文件越小,模型规模越小。

表3 不同检测算法的模型大小

Table 3 Model sizes of different detection algorithms

检测方法	骨干网络	模型大小/MB
YOLO V4	VGG-16	89.9
YOLO V4	GhostNet	42.5
YOLO V4	MobileNetV2	46.5
SSD	VGG-16	90.6
SSD-MobileNetV2(本文模型)		14.3

由表3可知,SSD-MobileNetV2模型大小仅为14.3 MB,约是标准SSD算法模型的1/6,是基于GhostNet^[25]骨架网络的YOLO算法模型的1/3。该模型大大减少了参数量和计算量,更加节省内存。综上所述,优化SSD-MobileNetV2模型更易于部署在煤矿井下算力有限的嵌入式设备上。

3.6 模型部署

为实现SSD-MobileNetV2模型在煤矿井下锚孔

识别检测中的实际应用,需将其部署到硬件平台上。结合本文任务需求,选择NVIDIA Jetson Xavier NX作为部署平台,如图11所示。Jetson Xavier NX尺寸为70 mm \times 45 mm,具有多个传感器接口、384个NVIDIA CUDA Cores、48个Tensor Cores、6块Carmel ARM CPU和2个NVIDIA深度学习加速器(NVDLA),能够满足部署SSD-MobileNetV2模型检测锚孔的需求。



图11 NVIDIA Jetson Xavier NX 模组

Fig. 11 NVIDIA Jetson Xavier NX

为提高模型在硬件平台上的运算速度,采用高性能深度学习推理优化器TensorRT对模型进行压缩

和优化。考虑到目前TensorRT不支持对SSD-MobileNetV2模型的直接转化,笔者以开放式模型文件格式ONNX作为中转,先将模型转化为ONNX模型,再将ONNX模型转化为TensorRT模型。

经TensorRT优化并部署到Jetson Xavier NX,锚孔检测模型参数和计算冗余大大缩减,在保证推理精度不受影响的前提下大幅度提高了推理速度,使得模型能够满足煤矿井下锚孔定位的实际应用要求。

4 结 语

(1) 为解决煤矿井下打锚任务中的锚孔识别问题,研究并提出了一种基于SSD-MobileNetV2深度神经网络的锚孔快速、准确识别方法。

(2) 通过对煤矿井下环境以及锚孔图像特点分析,建立了锚孔数据集,并针对锚孔小目标的特点优化了模型先验框设置方法,使得模型对锚孔检测的准确率提高了6%。

(3) 为提高模型检测速度,减小模型规模,优化了特征提取网络,采用MobileNetV2网络替代标准SSD检测算法中的VGG-16骨干网络,模型轻量化程度大幅提高。

(4) 试验结果表明,SSD-MobileNetV2模型能够快速、准确识别煤矿井下钢带锚孔,其优于其他一阶段检测算法。将模型部署到NVIDIA Jetson Xavier NX平台上,进一步验证了模型的可应用性。下一步研究将考虑本文检测算法与定位算法相结合,实现锚孔的自动定位。

参考文献(References):

- [1] 王国法,刘峰,庞义辉,等. 煤矿智能化——煤炭工业高质量发展的核心技术支撑[J]. 煤炭学报,2019,44(2): 349-357.
WANG Guofa, LIU Feng, PANG Yihui, et al. Coal mine intellectualization: The core technology of high quality development[J]. Journal of China Coal Society, 2019, 44(2): 349-357.
- [2] 葛世荣,郝尚清,张世洪,等. 我国智能化采煤技术现状及待突破关键技术[J]. 煤炭科学技术, 2020, 48(7): 28-46.
GE Shirong, HAO Shangqing, ZHANG Shihong, et al. Status of intelligent coal mining technology and potential key technologies in China[J]. Coal Science and Technology, 2020, 48(7): 28-46.
- [3] 王国法,庞义辉,任怀伟. 煤矿智能化开采模式与技术路径[J]. 采矿与岩层控制工程学报, 2020, 2(1): 013501.
WANG Guofa, PANG Yihui, REN Huaiwei. Intelligent coal mining pattern and technological path[J]. Journal of Mining and Strata Control Engineering, 2020, 2(1): 013501.
- [4] 王国法,张德生. 煤炭智能化综采技术创新实践与发展展望[J]. 中国矿业大学学报, 2018, 47(3): 459-467.
WANG Guofa, ZHANG Desheng. Practice and development prospect of technology innovation of intelligent coal comprehensive mining[J]. Journal of China University of Mining and Technology, 2018, 47(3): 459-467.
- [5] 薛光辉,程继杰,管健,等. 深部综掘巷道机器人化超前支护方案与最佳支护时机研究[J]. 矿业科学学报, 2019, 4(4): 349-356.
XUE Guanghui, CHENG Jijie, GUAN Jian, et al. Robotized advance support scheme and optimum support opportunity for deep fully mechanized roadway[J]. Journal of Mining Science and Technology, 2019, 4(4): 349-356.
- [6] PURKAIT P, ZHAO C, ZACH C. SPP-Net: Deep absolute pose regression with synthetic views[Z/OL]. <http://arxiv.org/abs/1712.03452>, 2017-12-09.
- [7] GIRSHICK R. Fast R-CNN[R/OL]. <http://arxiv.org/abs/1504.08083>, 2015-09-27.
- [8] DAI J, LI Y, HE K, et al. R-FCN: Object detection via region-based fully convolutional networks[R/OL]. <http://arxiv.org/abs/1605.06409>, 2016-06-21.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[A/OL]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)[C/OL]. Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [10] 张新钰,高洪波,赵建辉,等. 基于深度学习的自动驾驶技术综述[J]. 清华大学学报(自然科学版), 2018, 58(4): 438-444.
ZHANG Xinyu, GAO Hongbo, ZHAO Jianhui, et al. Overview of deep learning intelligent driving methods[J]. Journal of Tsinghua University (Science and Technology), 2018, 58(4): 438-444.
- [11] 贾可心,马正华,朱蓉,等. 注意力机制改进轻量SSD模型的海面小目标检测[J]. 中国图象图形学报, 2022, 27(4): 1161-1175.
JIA Kexin, MA Zhenghua, ZHU Rong, et al. Attention-mechanism-based light single shot multibox detector modelling improvement for small object detection on the sea surface[J]. Journal of Image and Graphics, 2022, 27(4): 1161-1175.
- [12] 杨桥,李自胜,王露明,等. 基于改进SSD算法的工件检测[J]. 组合机床与自动化加工技术, 2022(3): 68-71.
YANG Qiao, LI Zisheng, WANG Luming, et al. Workpiece detection based on improved SSD algorithm[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(3): 68-71.
- [13] 丁飞,石颀,吴宏杰. 改进YOLOv4的轻量级遥感图像建筑物检测模型[J/OL]. 计算机工程与应用: 1-10. <https://kns.cnki.net/kcms/detail/11.2127.TP.20220524.1035.007.html>, 2022-05-24.
DING Fei, SHI Jie, WU Hongjie. Lightweight building detection model based on YOLOv4 optimization for remote sensing images[J/OL]. Computer Engineering and Applications: 1-10. <https://kns.cnki.net/kcms/detail/11.2127.TP.20220524.1035.007.html>, 2022-05-24.
- [14] 杜虢龙,余华平. 基于改进Mobile Net-SSD网络的驾驶员分心行为检测[J]. 公路交通科技, 2022, 39(3): 160-166.

- DU Xiaolong, YU Huaping. Detecting driver's distracted behavior based on improved Mobile Net-SSD network[J]. *Journal of Highway and Transportation Research and Development*, 2022, 39(3): 160-166.
- [15] 苏钰桐, 杨炜毅, 李俊霖. 基于YOLOv3的煤岩钻孔图像裂隙智能识别方法[J]. *煤矿安全*, 2021, 52(4): 156-161.
- SU Yutong, YANG Weiyi, LI Junlin. Intelligent recognition method of borehole image fractures for coal and rock based on YOLOv3[J]. *Safety in Coal Mines*, 2021, 52(4): 156-161.
- [16] 孙传猛, 王燕平, 王冲, 等. 融合改进YOLOv3与三次样条插值的煤岩界面识别方法[J]. *采矿与岩层控制工程学报*, 2022, 4(1): 016522.
- SUN Chuanmeng, WANG Yanping, WANG Chong, et al. Coal-rock interface identification method based on improved YOLOv3 and cubic spline interpolation[J]. *Journal of Mining and Strata Control Engineering*, 2022, 4(1): 016522.
- [17] 张翼翔, 林松, 李雪. 基于CenterNet-GhostNet的选煤厂危险区域人员检测[J]. *工矿自动化*, 2022, 48(4): 66-71.
- ZHANG Yixiang, LIN Song, LI Xue. Personnel detection in dangerous areas of coal preparation plants based on CenterNet-GhostNet[J]. *Journal of Mine Automation*, 2022, 48(4): 66-71.
- [18] 梁鸿, 王庆玮, 张千, 等. 小目标检测技术研究综述[J]. *计算机工程与应用*, 2021, 57(1): 17-28.
- LIANG Hong, WANG Qingwei, ZHANG Qian, et al. Small object detection technology: A review[J]. *Computer Engineering and Applications*, 2021, 57(1): 17-28.
- [19] 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. DOI: 10.1109/TPAMI. 2016.2577031.
- [20] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[A]. *Proc of European Conference on Computer Vision*[C]. Springer, 2016: 21-37.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[Z/OL]. <http://arxiv.org/abs/1409.1556>, 2015-04-10.
- [22] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks[Z/OL]. <http://arxiv.org/abs/1801.04381>, 2019-03-21.
- [23] EVERINGHAM M, VAN Gool L, WILLIAMS C K I, et al. The pascal visual object classes (VOC) challenge[J]. *International Journal of Computer Vision*, 2010, 88(2): 303-338.
- [24] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[Z/OL]. <http://arxiv.org/abs/2004.10934>, 2020-04-23.
- [25] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[Z/OL]. <http://arxiv.org/abs/1911.11907>, 2020-03-13.