

# 基于 YOLO v5-IBX 网络模型的公路 隧道衬砌裂缝检测方法研究

何兆益<sup>1</sup>, 常宝霞<sup>1,2</sup>, 吴逸飞<sup>3</sup>, 李冬雪<sup>1</sup>

(1. 重庆交通大学交通运输学院, 重庆 400074; 2. 陕西服装工程学院信息工程学院, 陕西  
西安 712046; 3. 重庆奉建高速公路有限公司, 重庆 404600)

**摘要** 目的 针对传统隧道衬砌裂缝检测效率低、成本高、周期长以及当前基于计算机视觉、图像处理技术的裂缝智能检测方法效率低、精度低、检测结果不准确等问题, 提出一种改进的网络模型 YOLO v5-IBX 对公路隧道衬砌裂缝进行智能检测。方法 在原始 YOLO v5 网络模型的检测层中新增一个低维尺度和在特征提取层中融入注意力机制, 提高特征融合利用和对小目标的检测精度, 降低网络参数的计算量, 达到减少裂缝细节信息丢失的目的; 对采集到的公路隧道衬砌裂缝图像, 通过图像翻转、裁剪、调整图像饱和度、对比度等随机转换方式来进行数据增强, 增加数据特征样本, 建立数据集, 以满足模型检测的需求; 在建立的隧道衬砌裂缝数据集上进行试验, 以精确率、召回率、计算平均精度及平均精度均值作为检测精度的综合评价指标, 将笔者提出的网络模型 YOLO v5-IBX 与原始的 YOLO v5 等其他网络模型进行对比。结果 采用改进的网络模型 YOLO v5-IBX 检测隧道衬砌裂缝, 在迭代 300 次的情况下, 训练损失可以降低到 0.014, 裂缝检测精度率达到 97.8% 左右, 召回率达到 97.7% 左右, 精度均值达到 98.6% 左右, 均优于其他模型, 检测精度得到有效提高。结论 相比较传统的人工检测方法和原始 YOLO v5 检测算法, 改进的网络模型 YOLO v5-IBX 可以更快速、准确地识别出隧道衬砌裂缝, 为隧道衬砌裂缝检测提供新的更加实用的检测方案。

**关键词** 公路隧道; 裂缝检测; YOLO v5-IBX 模型; 隧道衬砌裂缝; 注意力机制

中图分类号 U457

文献标志码 A

## Research on Crack Detection Method of Highway Tunnel Lining Based on YOLO v5-IBX Network Model

HE Zhaoyi<sup>1</sup>, CHANG Baoxia<sup>1,2</sup>, WU Yifei<sup>3</sup>, LI Dongxue<sup>1</sup>

(1. School of Transportation, Chongqing Jiaotong University, Chongqing, China, 400074; 2. School of Information Engineering, Shaanxi Fashion Engineering University, Xi'an, China, 712046; 3. Chongqing Fengjian Expressway Co. Ltd., Chongqing, China, 404600)

收稿日期: 2022-09-16

基金项目: 国家重点研发计划项目(2018YFB1600201); 交通运输部科技示范项目(2021-581)

作者简介: 何兆益(1965—), 男, 教授, 博士生导师, 主要从事道路工程等方面研究。

**Abstract:** Aiming at the problems such as low efficiency, high cost and long cycle of traditional tunnel lining crack detection, low efficiency, low precision and inaccurate detection results of current intelligent crack detection methods based on computer vision and image processing technology, this study proposed an improved network model YOLO v5-IBX for intelligent crack detection of highway tunnel lining. A new low-dimensional scale is added to the detection layer of the original YOLO v5 network model and attention mechanism is integrated into the feature extraction layer, which improves the feature fusion utilization and detection accuracy of small targets, reduces the calculation amount of network parameters, and achieves the purpose of reducing the loss of crack details. The collected highway tunnel lining crack images are enhanced by random conversion methods such as image flipping, clipping, adjusting image saturation, contrast, etc. to increase data feature samples and build data sets to meet the needs of model detection. The network model YOLO V5-IBX proposed in this study was compared with other network models such as the original YOLO v5, using the accuracy rate, recall rate, calculated average accuracy and average accuracy mean as comprehensive evaluation indexes of detection accuracy. The test results show that the network model YOLO v5-IBX proposed in this study can detect tunnel lining cracks. In the case of 300 iterations, the training loss can be reduced to 0.014, the crack detection accuracy rate is about 97.8%, the recall rate is about 97.7%, and the average accuracy is about 98.6%, all of which are better than other models. The detection accuracy is effectively improved. Compared with the traditional manual detection method and the original YOLO v5 detection algorithm, the network model YOLO V5-IBX proposed in this study can identify tunnel lining cracks more quickly and accurately, providing a new and more practical detection scheme for tunnel lining crack detection.

**Key words:** tunnel engineering; crack detection; YOLO v5-IBX network model; tunnel lining cracks; attentional mechanism

衬砌裂缝是公路隧道施工和运营过程中最常出现的病害,影响隧道的结构稳定及安全行车。传统裂缝的检测和识别主要依靠人工巡检,不仅效率低、准确率低且容易出现漏检情况,无法满足隧道裂缝快速检测的要求。而主流的数字图像处理技术和机器视觉方法因隧道图像中存在水渍、划痕、光照不均匀、噪声大等复杂情况,导致其效率低、准确率低且实时性差,因此需要更有效的方法对隧道衬砌裂缝及时检测。

在隧道图像的数据采集中,江桁等<sup>[1]</sup>采用上海同岩公司开发的公路隧道快速检测车采集隧道图像,其图像采集成本较高;孟庆成等<sup>[2]</sup>采用智能手机采集图像,其采集过程较为主观;I. Kim 等<sup>[3]</sup>采用无人机自带的线阵相机获取采集图像,其采集方式在隧道中使用受限。因此,笔者考虑到研究的实用性与经济性,选用较普遍的单反相机。

在大数据时代,不少研究学者用深度学习的检测方法检测隧道衬砌裂缝<sup>[4-6]</sup>。赵慧洁等<sup>[7]</sup>对神经元模型改良,得到脉冲耦合神经网络。但因衬砌裂缝图像的复杂性,所用的分割方式不能充分提取图像信号,分离效率不佳。Y. J. Cha 等<sup>[8]</sup>基于滑动窗口扫描技术设计了一种卷积神经网络识别混凝土裂缝,通过与传统边缘检测技术(如 Canny<sup>[9]</sup>、Sobel<sup>[10]</sup>算子)的识别方法比较发现,裂缝识别时深度学习技术优于数字图像处理方式。F. C. Chen<sup>[11]</sup>将滑动窗口扫描技术应用于深度卷积神经网络中进行视频序列的裂缝识别,考虑到视频序列中裂缝在时空上的一致性,给出一个融合各种频率序列和结合贝叶斯决策的数据融合方法,以减少错误率。刘新根等<sup>[12]</sup>基于深度学习提出一种隧道衬砌裂缝自动识别算法,验证了深度学习识别裂缝的优越性。沙爱民等<sup>[13]</sup>将卷积神经网络

技术运用于道路病害识别与检测中,发现经图形处理器加速,卷积神经网络检测效率较高。李建超等<sup>[14]</sup>分析了隧道衬砌裂缝检测系统的不足,提出基于图像识别技术的裂缝检测系统,可对后端裂缝快速识别并提取裂缝特征,但该方法精度仅有70%。刘新根等<sup>[15]</sup>基于卷积神经网络,提出二叉树与曲线拟合的裂缝识别方法,可以较好地修正裂缝边缘,但对于水渍、划痕等伪裂缝未作判断。柴雪松等<sup>[16]</sup>采用超像素对包含裂缝的区域先分类再分割,实现裂缝识别,但超像素对背景干扰较多且特征不明显的裂缝分块效果不佳。Z. Qu等<sup>[17]</sup>提出接缝消除算法和渗流检测算法相结合的隧道裂缝检测算法,可以去掉表面噪声,但精度受环境影响较大。Z. Zhou等<sup>[18]</sup>提出一种YOLO v4-ED算法,对隧道裂缝实现了自动化检测,但检测精度还有待优化。

综上所述,进行隧道裂缝识别时,神经网络系统只有设备好、训练时间长、数万次训练后,裂缝识别精度才能较高<sup>[19-20]</sup>,这无法满足隧道衬砌裂缝检测成本低、操作简单、效率高的现实要求。为保证隧道长期安全稳定地运行,笔者针对隧道衬砌裂缝检测面临的实

际困难,在原始YOLO v5网络模型的检测层中新增一个低维尺度和在特征提取层中融入注意力机制,提出改进的网络模型YOLO v5-IBX,对其公路隧道衬砌裂缝进行检测;研究表明,笔者所提方法高效、灵活、成本低,可以快速地对公路隧道衬砌裂缝进行检测。

1 研究方法

YOLO算法在检测的实时性方面具有独特优势,随着技术的不断改进,YOLO系列网络已经从初始的YOLO v1模型逐渐进步为目前的YOLO v5模型,本研究中主要需要识别的目标为公路隧道衬砌表观的裂缝,对模型的实时性和轻量化都有较高的要求,因此选取YOLO v5网络。从原始的YOLO v1模型到较新的YOLO v5模型的优缺点,如表1所示。YOLO v5架构包含四个架构,分别命名为YOLO v5s、YOLO v5m、YOLO v5l和YOLO v5x21<sup>[21]</sup>。主要区别在于网络具体位置的特征提取模块和卷积核的数量不同,四种体系结构的模型尺寸和模型参数数量依次增加。在这四种架构中,YOLO v5s相对来说是较轻快的模型。

表1 YOLO系列算法优缺点

Table 1 Advantages and disadvantages of the YOLO series algorithms

算法	优点	缺点
YOLO v1	检测速度相对有所提升	对小目标和密集目标检测效果不佳
YOLO v2	分类精度有所提升	需要预训练,小目标检测效果不佳
YOLO v3	实现多尺度检测	模型较为复杂,中大目标检测效果较差
YOLO v4	权衡了精度与速度之间的关系	检测精度有待进一步提升
YOLO v5	模型尺寸小,检测精度相对较高	性能有待进一步提升

由于隧道衬砌裂缝图像受隧道中光照、噪声的影响,为了提高目标检测精度,本研究基于YOLO v5构架,在检测层网络中,新增一个160×160的低维尺度,原YOLO v5采用20×20,40×40,80×80的三种尺度对特征进行融合,尚未完全利用网络中分辨率较大的浅层特征图的位置信息,直接采用此网

络进行检测,在多次卷积后会使得部分隧道衬砌裂缝图像信息丢失,不能很好完成检测任务。加入低维尺度后,通过融合多种尺度的特征信息进行隧道衬砌裂缝检测,可以强化特征学习。并在特征提取层融入SE注意力机制,可以更好地提取衬砌裂缝图像的目标特征。SE注意力机制(Squeeze-and-

Excitation Networks, SENet)<sup>[22]</sup> 是一种用于改善神经网络特征提取能力的通道注意力机制。对于任意给定的输入  $X(X \in RH \times W \times C)$  经过变换 (Transformation) 做一次卷积映射,映射到特征  $U$  上,其中  $U \in RH \times W \times C$ ,通过卷积操作,可以构造相应的 SE 模块来执行特征的校准工作。SE 模块包括压缩和激励两个步骤,在压缩过程中,特征  $U$  先经过全局平均池化变换,将  $C \times H \times W$  的特征图压缩为一个  $C \times 1 \times 1$  的特征图。这个特征图包含了输入特征图中每个通道的平均值,用于表示该通道的重要性。在激励过程中,SE 模块通过采用一个全连接神经网络将  $C \times 1 \times 1$  的特征图映射到一个  $C$  维的向量,然后通过一个 Sigmoid 激活函数将向量中的

每个元素压缩到 0 到 1 之间。这个向量表示了每个通道的重要性权重,用于调整输入特征图中每个通道的响应。最后,SE 模块将调整后的特征图与原始特征图进行比例相乘 (Scale) 运算,得到被赋予了相应注意力权重的特征图  $X^{\sim}$ 。这个特征图可以用于后续的分类和检测。SE 注意力机制可以根据数据的特征自动调整每个通道的重要性权重,通过特征映射生成的通道描述符来提升有用的特征,同时弱化噪声和背景等不重要的特征,从而能在保证准确的同时提高网络速度,更好地适应现场应用环境。因此,将 YOLO v5-IBX 目标检测方法应用于隧道衬砌裂缝检测。

YOLO v5-IBX 作为隧道衬砌裂缝检测的网络模型,其结构如图 1 所示。

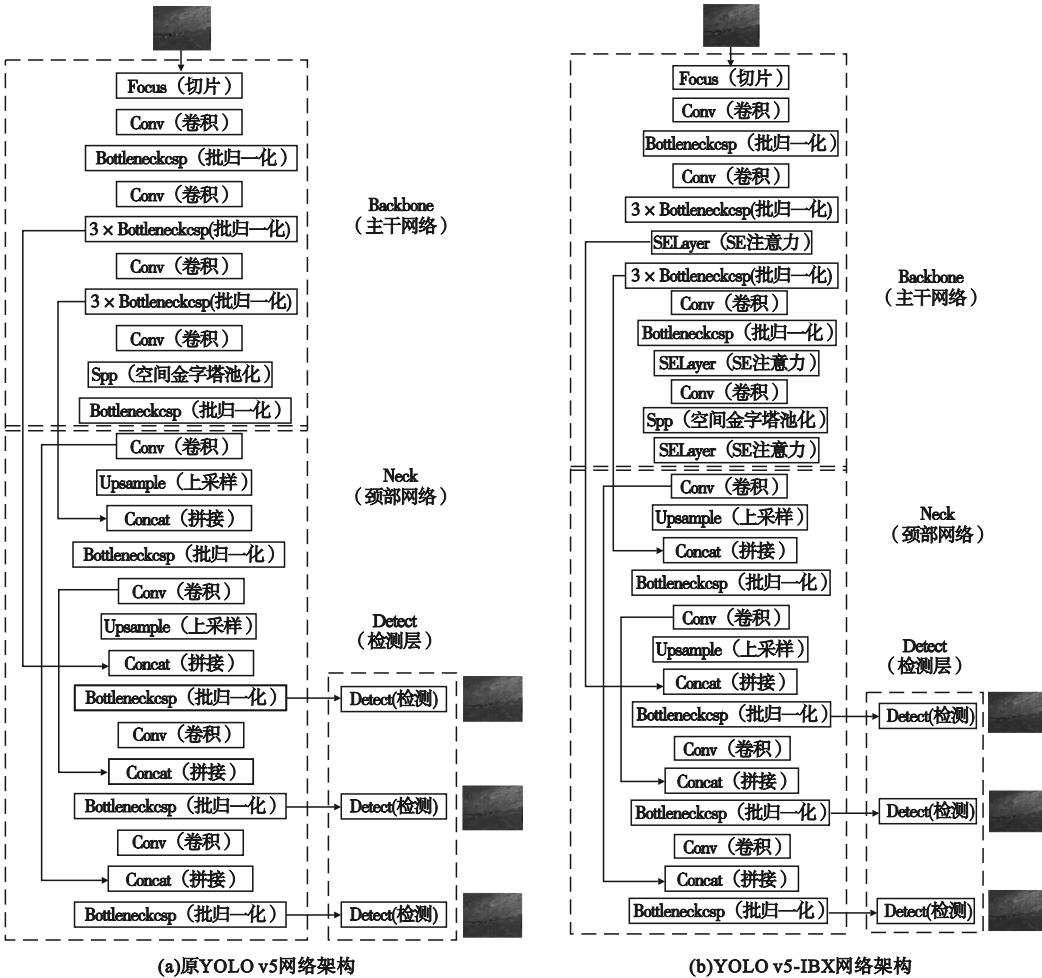


图 1 YOLO v5 网络结构图

Fig. 1 The network structure of YOLO v5



2 数据采集及处理

2.1 数据采集

目前,国内还没有公开的隧道衬砌裂缝数据集,为了达到研究目的,笔者以重庆涪陵区打石场隧道为研究对象进行数据采集。打石场隧道位于 G319 厦成线涪陵段,洞门为端墙式结构,隧道长 848.5 m,高 7.3 m,路面

宽 8.1 m,检修道宽度为 0.9 m;衬砌为复合式结构,路面为沥青混凝土结构。

通过使用单反相机,共拍摄 1 452 张裂缝图像,图像格式为 jpg,每张图片分辨率为 4 032 × 3 024 dpi,位深度为 24 bit,建立了一个隧道衬砌裂缝数据集,选取的部分样本图像如图 2 所示。




图 2 隧道衬砌裂缝样例

Fig. 2 The crack samples of tunnel lining

2.2 数据处理

由于隧道内部环境较暗,采集图像时隧道采光不均匀,不可避免地出现采集到的图像光照不均匀的现象,而隧道衬砌背景较复杂且裂

缝较窄,导致裂缝检测精度不高,这些都对隧道衬砌裂缝的标注有了不同的需求。从 1452 个标注的样本中选取 5 个典型的隧道衬砌裂缝图像,展示裂缝标注的不同情形,如图 3 所示。




图 3 不同情形隧道衬砌裂缝图标注样例

Fig. 3 The different types of crack for tunnel lining

由图 3 可以看出,隧道衬砌裂缝背景复杂。首先,隧道衬砌表面光照不均匀导致图像裂缝像素亮度不均匀;其次,隧道衬砌裂缝

呈线状、拉长状,中间可能出现断裂和交叉;然后,隧道衬砌表面受到油渍或水渍的污染,使得裂缝像素与背景像素难以区分;最后,隧

道衬砌裂缝图像中的裂缝像素在图像总像素中所占比例很低,导致检测时样本负荷较大。

数据集是网络模型训练的基础,而数据标注也是直接影响数据集质量的重要因素。本研究采用 LabelImg 对采集到的图像进行标注,标注后的图像命名为 crack。在标注完成后,保存自动生成的 XML 文件,然后利用 LabelImg 系统将 XML 文件转换为裂缝图像标注信息的 TXT 文件,文件中含有裂缝的数量和位置信息。目前获取的数据集不能满足模型训练的需求,所以需要在现有的数据集基础上进行数据增强,通过翻转、裁剪和调整图像对比度、饱和度、亮度来使采集到的 1 452张图像扩充到 3 630 张,增大数据特征样本,以满足训练需求。裂缝标注信息情况如表 2 所示,其中,“0”代表的是隧道衬砌中的裂缝类型,“0”的个数代表的是所标注的裂缝条数。坐标 1 代表的是标注框的中心点横坐标,坐标 2 代表的是标注框的中心点纵坐标,坐标 3 代表的是标注框的宽度,坐标 4 代表的是标注框的高度。

表 2 裂缝标注信息情况表

Table 2 The labelled information of cracks				
类别代码	坐标 1	坐标 2	坐标 3	坐标 4
0	0.500 946	0.592 616	0.998 108	0.196 496
0	0.500 473	0.589 487	0.999 054	0.205 257
0	0.323 271	0.182 909	0.352 360	0.353 823
⋮	⋮	⋮	⋮	⋮
0	0.757 409	0.604 198	0.485 181	0.494 753
0	0.652 778	0.475 033	0.192 460	0.116 733
0	0.398 934	0.592 923	0.124 752	0.275 794

3 试验分析

3.1 试验方案

本试验使用 Intel Core i5 2520M 主频 2.5 GHz 处理器,16G 内存,NVIDIA Optimus NV5400M,8G 独立显存硬件环境,操作系统为 Windows10。开发平台使用 Pycharm,使用基于 Python 语言的 Tensorflow 深度学习框架搭建 YOLO v5-IBX,实现网络模型对公

路隧道衬砌裂缝的检测。

本研究将打石场隧道衬砌裂缝的 3 630 张图像作为数据集,其中训练集图像 2 904 张,验证集图像 726 张,基于 YOLO v5-IBX 网络模型检测图像中的衬砌裂缝。在模型训练时,设置参数批尺寸为 96,迭代次数为 300 次,动量为 0.937,权重衰减值为 0.000 5,学习率初始值为 0.01。在训练过程中,采用梯度优化器对网络模型参数进行更新,同时采用小批量梯度下降法进行迭代训练。在每次迭代中,计算损失函数的输出值,以评估模型的性能和训练进度,随着损失函数的输出值逐渐变小并趋于稳定,迭代过程会自动停止。此时网络模型已经训练完毕,保存网络模型的权重,将该权重用于公路隧道衬砌裂缝图像的检测。笔者改进的 YOLO v5-IBX 网络模型采用端到端的随机梯度下降(SGD)方法进行训练,设置训练次数为 350 次,但在训练 300 次后,损失函数曲线趋于平滑稳定,所以最终训练的次数为 300 次。保存训练后的权重文件,利用测试集对模型性能进行评估。

3.2 研究评价指标

在目标检测时,通常将预测框与目标真实框的交并比大于 0.5 设定为成功预测到目标位置,通过精确率  $P$ 、召回率  $R$ 、计算平均精度  $AP$  和平均精度均值  $mAP$  作为目标检测精度的综合评价指标。其中,精确率体现为所有预测为裂缝的目标中,预测准确的目标占整个所有检测为裂缝的比例,反映模型的误判能力,其主要衡量公路隧道衬砌裂缝检测模型正确分类的程度。召回率体现为正确预测为裂缝的数量占有所有检测样本中裂缝数量的比例,反映模型的漏检能力。 $AP$  用于评估模型在单个检测类别上精度,而  $mAP$  评估整体检测精度,由于本研究中隧道衬砌裂缝只有一种类型, $AP$  与  $mAP$  取值相同,因此采用计算平均精度和平均精度均值评价裂缝检测精度效果一致。 $mAP$  越大,表明检测精度越高,效果越好,具体计算公式为

$$P=\frac{Z_j}{Z_j+F_j}.$$

(1)

$$R=\frac{Z_j}{Z_j+F_N}.$$

(2)

$$AP=\int_0^1JHdH.$$

(3)

$$mAP=\frac{\sum_{i=1}^cAP_i}{c}.$$

(4)

式中: $Z_j$  为识别出裂缝的正样本条数; $F_j$  为无裂缝识别的负样本条数; $F_N$  为含有未识别裂缝的正样本条数; $c$  为分类数。

3.3 训练结果分析


训练结果如表3和图4所示。在迭代

0~100次时,曲线变化幅度很大;在迭代100次以后,曲线趋势逐渐缓和,最后在靠近300次时趋于稳定。在迭代300次后,边界框回归损失最后值约为0.014,该值越小,训练时的损失就越小,表明训练的结果越准确。置信度损失值约为0.009,该值越小,说明检测精度越高。由于样本中只有一个标注类别,标记为crack,所以该类类别值为0;裂缝识别精确率约为97.8%,则误判率为2.2%,说明裂缝检测精度较高;召回率约为97.7%,则漏检率为2.3%,说明查找正确含裂缝类型的准确率较高;平均精度均值为98.6%,说明模型训练较好。


表3 裂缝训练结果

Table 3 The results of fracture training

迭代/次	边界框损失	置信度损失	类别	<i>P</i>	<i>R</i>	<i>mAP</i> @0.5	<i>mAP</i> @0.5:0.95
0	0.038 659	0.030 251	0	0.000 785	0.187 500	0.000 624	0.000 117
1	0.037 095	0.030 022	0	0.000 969	0.231 360	0.000 565	0.000 160
2	0.036 573	0.030 743	0	0.001 446	0.345 390	0.001 024	0.000 353
3	0.035 921	0.029 558	0	0.001 864	0.442 980	0.028 114	0.001 612
4	0.035 137	0.027 928	0	0.001 703	0.406 800	0.029 430	0.004 191
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
295	0.014 166	0.009 249	0	0.981 180	0.973 680	0.992 240	0.835 000
296	0.014 081	0.009 288	0	0.982 410	0.971 490	0.986 830	0.834 520
297	0.014 296	0.009 050	0	0.980 320	0.972 590	0.987 870	0.834 480
298	0.014 370	0.009 135	0	0.977 900	0.976 970	0.986 500	0.839 370
299	0.014 083	0.009 072	0	0.978 050	0.977 060	0.986 830	0.839 320



(a)边界框损失曲线



(b)置信度损失曲线




图4 训练结果

Fig. 4 The training results

3.4 试验结果对比分析

为了更好地验证笔者改进的 YOLO v5-IBX 公路隧道衬砌裂缝检测模型的提升效果,基于 3.1 试验方案与数据集,对原始的 YOLO v5 检测模型进行训练,对比模型性能,对比结果如表 4 和图 5 所示。

表4 模型性能对比

Table 4 The comparison of model performance				
方法	P/%	R/%	mAP@0.5/ %	mAP@0.5:0.95/ %
YOLO v5-IBX	97.8	97.7	98.6	83.9
YOLO v5	86.9	83.9	88.5	75.4

注:mAP@0.5 和 mAP@0.5:0.95 中 m 表示平均,@ 后面的数表示判定交并比为正负样本的阈值,@ 0.5:0.95 表示阈值取 0.5:0.05:0.95(从 0.5 到 0.95,步长为 0.05)后取均值。

通过对比发现,改进的 YOLO v5-IBX 模型在训练集上的精确率达到 97.8% 左右,

召回率达到 97.7% 左右,都高于原 YOLO v5 模型的精确率和召回率,分别为 86.9% 和 83.9%,分别提升 10.9% 和 13.8%;在阈值为 0.5 时,改进的 YOLO v5-IBX 模型平均检测精度为 98.6%,YOLO v5 模型的平均检测精度为 88.5%,提升 10.1%;在阈值为 0.5:0.95 时,笔者改进的 YOLO v5-IBX 模型的平均检测精度为 83.9%,YOLO v5 模型的平均检测精度为 75.4%,提升 8.5%。由检测结果分析可知,笔者改进的 YOLO v5-IBX 模型优于 YOLO v5 模型。

为进一步分析该算法对衬砌裂缝的识别性能,将改进的 YOLO v5-IBX 网络与原始的 YOLO v5、YOLO v3、YOLO v4、Faster R-CNN 网络进行比较。以模型的精确率、召回率、平均精度均值和权重大小作为评价指标,每个网络模型的识别结果如表 5 所示。



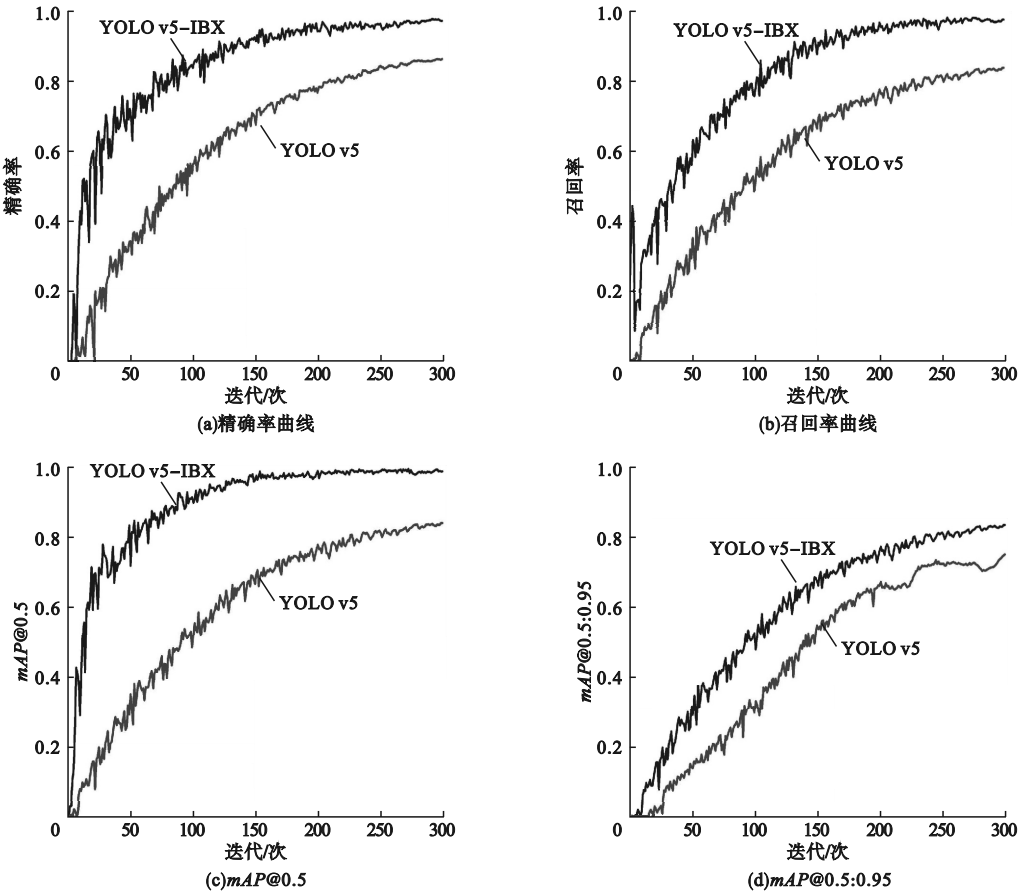


图5 改进前后模型对比

Fig. 5 The comparison before and after model improvement

表5 不同模型在隧道裂缝检测中性能对比

Table 5 The performance comparison of different models in tunnel crack detection

算法	$P/\%$	$R/\%$	$mAP/\%$	权重/MB
YOLO v5	86.9	83.9	88.5	27.5
YOLO v3	81.5	79.6	83.9	226.0
YOLO v4	84.3	83.1	86.4	243.0
Faster R-CNN	89.2	88.7	91.3	308.0
YOLO v5-IBX	97.8	97.7	98.6	25.2

通过对比发现,本研究改进的 YOLO v5-IBX 识别模型的精确率、召回率、平均精度均值分别达到 97.8%、97.7%、98.6%,权重仅有 25.2 MB,均优于其他方法。这说明笔者改进的隧道衬砌裂缝检测模型在满足检测精度、轻量化等要求的同时,优于其他算法,不仅保证了识别的准确性,还满足隧道衬砌裂缝检测的实际需求。

3.5 测试结果

曲线在训练 300 次时趋于平稳,表明模型训练良好,没有过拟合。为验证公路隧道衬砌裂缝检测模型的性能,随机选取数据集中 726 张图像进一步分析该模型的检测结果。检测结果显示,该模型对于隧道衬砌裂缝图像能够较好地识别检测,通过在特征层引入注意力机制,可以更加有效地提取隧道衬砌裂缝特征,增强深度,满足衬砌裂缝的日

常检测要求。从验证的 726 张裂缝图像中,选取以下三种较典型的衬砌裂缝进行分析,

如图 6 所示。




图 6 裂缝验证结果

Fig. 6 The test results of crack detection

从图 6 中可以看出,对于背景简单和背景复杂、干扰较多的隧道衬砌裂缝,该模型都能很好地识别并标记出来,且对非裂缝没有误判。在背景简单的隧道衬砌中,可以准确地识别出细小裂缝。在背景复杂的隧道衬砌中,该模型能够很好地区分出真实裂缝与伪裂缝。证明了笔者改进的 YOLO v5-IBX 网络模型可以满足公路隧道衬砌裂缝检测高精度、高效、实时性等实际要求。

## 4 结 论

(1) 基于原 YOLO v5 架构,在检测层中新增一个低维尺度和在特征提取层中融入注意力机制,提出一种改进的 YOLO v5 检测算法模型 YOLO v5-IBX,增加特征融合地利用,减少网络参数的计算量,提高对小目标的检测精度,能够满足公路隧道衬砌裂缝检测高精度、高效、实时性的实际要求。

(2) 采用笔者改进的公路隧道衬砌裂缝检测模型 YOLO v5-IBX 对裂缝进行检测时,比原来的 YOLO v5 以及其他网络模型检测效果要好;经过 300 次训练后,总损失率降低到 0.014 左右,裂缝检测精确率达到 97.8% 左右,召回率达到 97.7%,精度均值达到 98.6% 左右,并且每帧图像的检测时间达到 0.021 s,权重仅有 25.2MB;在提高检测精度的情况下,保证了模型检测时间和网络轻量化,优化了检测模型,为隧道衬砌裂缝检测提供了新的更加实用的检测方案。

(3) 采用本研究改进的公路隧道衬砌裂缝检测模型,对于隧道衬砌背景复杂,干扰较多的情况,没有误判,没有漏检,能够有效地区分真实裂缝与伪裂缝;经后期人工复核,证实检测效果较好,且对于隧道拱顶的检测较人工检测方法更为准确与高效。

## 参考文献

- [1] 江桁,刘学增,朱合华. 基于隧道快速检测车数据的公路隧道衬砌开裂识别模型研究[J]. 现代隧道技术,2020,57(5):61-65.  
(JIANG Heng, LIU Xuezheng, ZHU Hehua. Research on crack identification of highway tunnel linings based on data obtained from the testing vehicle [J]. Modern tunnelling technology, 2020, 57(5): 61-65.)
- [2] 孟庆成,万达,吴浩杰,等. 基于卷积神经网络的混凝土裂缝图像识别方法[J]. 沈阳建筑大学学报(自然科学版),2021,37(5):832-840.  
(MENG Qingcheng, WAN Da, WU Haojie, et al. Image recognition method of concrete cracks based on convolutional neural network [J]. Journal of Shenyang jianzhu university (natural science), 2021, 37(5): 832-840.)
- [3] KIM I, JEON H, BAEK S, et al. Application of crack identification techniques for an aging concrete bridge inspection using an unmanned aerial vehicle [J]. Sensors, 2018, 18(6): 1881.
- [4] 王琨. 基于深度学习的路面破损检测研究及应用[D]. 武汉:武汉理工大学,2019.  
(WANG Kun. Research and application of pavement distress detection based on deep learning [D]. Wuhan: Wuhan University of Technology, 2019.)
- [5] 杨杰文,章光,陈西江,等. 基于深度学习的较复杂背景下桥梁裂缝检测[J]. 铁道科学与工程学报,2020,17(11):2722-2728.  
(YANG Jiewen, ZHANG Guang, CHEN Xijiang, et al. Research on bridge crack detection based on deep learning under complex background

- [J]. Journal of railway science and engineering, 2020, 17(11): 2722 - 2728. )
- [6] 曹锦纲, 杨国田, 杨锡运. 基于注意力机制的深度学习路面裂缝检测[J]. 计算机辅助设计与图形学学报, 2020, 32(8): 1324 - 1333.  
(CAO Jingang, YANG Guotian, YANG Xiyun. Pavement crack detection with deep learning based on attention mechanism [J]. Journal of computer-aided design & computer graphics, 2020, 32(8): 1324 - 1333. )
- [7] 赵慧洁, 葛文谦, 李旭东. 最小误差准则与脉冲耦合神经网络的裂缝检测[J]. 仪器仪表学报, 2012, 33(3): 637 - 642.  
(ZHAO Huijie, GE Wenqian, LI Xudong. Detection of crack defect based on minimum error and pulse coupled neural networks [J]. Chinese journal of scientific instrument, 2012, 33(3): 637 - 642. )
- [8] CHA Y J, CHOI W, BÜYÜKÖZTÜRK O. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-aided civil and infrastructure engineering, 2017, 32(5): 361 - 378.
- [9] 黄时杰, 曾建华. 图像边缘检测与分割的MATLAB实现[J]. 赤峰学院学报(自然科学版), 2019, 35(9): 47 - 49.  
(HUANG Shijie, ZENG Jianhua. MATLAB implementation of image edge detection and segmentation [J]. Journal of Chifeng university (natural science edition), 2019, 35(9): 47 - 49. )
- [10] 吴术路. 基于 Sobel 算子图像边缘检测的MATLAB实现[J]. 电脑知识与技术, 2010, 6(19): 5314 - 5315.  
(WU Shulu. Based on sobel edge detection operator of MATLAB implementation [J]. Computer knowledge and technology, 2010, 6(19): 5314 - 5315. )
- [11] CHEN F C, JAHANSHAH R M R. NB-CNN: deep learning-based crack detection using convolutional neural network and Naïve Bayes data fusion [J]. IEEE transactions on industrial electronics, 2018, 65(5): 4392 - 4400.
- [12] 刘新根, 陈莹莹, 朱爱玺, 等. 基于深度学习的隧道裂缝识别方法[J]. 广西大学学报(自然科学版), 2018, 43(6): 2243 - 2251.  
(LIU Xin'gen, CHEN Yingying, ZHU Aixi, et al. Tunnel crack identification based on deep learning [J]. Journal of Guangxi university (natural science edition), 2018, 43(6): 2243 - 2251. )
- [13] 沙爱民, 童峥, 高杰. 基于卷积神经网络的路表病害识别与测量[J]. 中国公路学报, 2018, 31(1): 1 - 10.  
(SHA Aimin, TONG Zheng, GAO Jie. Recognition and measurement of pavement disasters based on convolutional neural networks [J]. China journal of highway and transport, 2018, 31(1): 1 - 10. )
- [14] 李健超, 张翠兵, 柴雪松, 等. 基于图像识别技术的隧道衬砌裂缝检测系统研究[J]. 铁道建筑, 2018, 58(1): 20 - 24.  
(LI Jianchao, ZHANG Cuibing, CHAI Xuesong, et al. Research on crack detection system of tunnel lining based on image recognition technology [J]. Railway engineering, 2018, 58(1): 20 - 24. )
- [15] 刘新根, 陈莹莹, 王雨萱, 等. 基于级联神经网络的隧道衬砌裂缝识别算法研究[J]. 铁道学报, 2021, 43(10): 127 - 135.  
(LIU Xin'gen, CHEN Yingying, WANG Yuxuan, et al. Research on tunnel lining crack identification algorithm based on cascade neural network [J]. Journal of the China railway society, 2021, 43(10): 127 - 135. )
- [16] 柴雪松, 朱兴永, 李健超, 等. 基于深度卷积神经网络的隧道衬砌裂缝识别算法[J]. 铁道建筑, 2018, 58(6): 60 - 65.  
(CHAI Xuesong, ZHU Xingyong, LI Jianchao, et al. Tunnel lining crack identification algorithm based on deep convolutional neural network [J]. Railway engineering, 2018, 58(6): 60 - 65. )
- [17] QU Z, BAI L, AN S Q, et al. Lining seam elimination algorithm and surface crack detection in concrete tunnel lining [J]. Journal of electronic imaging, 2016, 25(6): 063004.
- [18] ZHOU Z, ZHANG J, GONG C. Automatic detection method of tunnel lining multi-defects via an enhanced you only look once network [J]. Computer-aided civil and infrastructure engineering, 2022, 37(6): 762 - 780.
- [19] 杨文伟, 杨霞, 蒙卉恩. 基于压电陶瓷的PVA-ECC混凝土柱裂缝损伤监测[J]. 沈阳建筑大学学报(自然科学版), 2020, 36(4): 628 - 636.  
(YANG Wenwei, YANG Xia, MENG Huien. Crack damage monitoring of PVA-ECC columns based on piezoelectric transducer [J]. Journal of Shenyang jianzhu university (natural science), 2020, 36(4): 628 - 636. )
- [20] 李太文, 范昕炜. 基于 Faster R-CNN 的道路裂缝识别[J]. 电子技术应用, 2020, 46(7): 53 - 56.  
(LI Taiwen, FAN Xinwei. Road crevice recognition based on faster R-CNN [J]. Application of electronic technique, 2020, 46(7): 53 - 56. )
- [21] LI Yuanhong, ZHAO Zuoxi, LUO Yangfan, et al. Real-time pattern-recognition of GPR images with YOLO v3 implemented by tensorflow. [J]. Sensors, 2020, 20(22): 6476.
- [22] MI Zhiwen, ZHANG Xudong, SU Jinya, et al. Wheat stripe rust grading by deep learning with attention mechanism and images from mobile devices [J]. Frontiers in plant science, 2020, 11: 558126.

(责任编辑: 刘春光 英文审校: 范丽婷)