

基于YOLOv5的桥梁裂纹检测方法研究

李军, 刘念, 张世义

引用本文

李军, 刘念, 张世义. 基于YOLOv5的桥梁裂纹检测方法研究[J]. 计算机科学, 2024, 51(11A): 231200063-7.

LI Jun, LIU Nian, ZHANG Shiyi. Study on Detection Method of Bridge Crack Based on YOLOv5[J]. Computer Science, 2024, 51(11A): 231200063-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[一种改进的基于YOLOv5s的轻量化航拍目标检测模型](#)

Improved Lightweight Aerial Photography Object Detection Model Based on YOLOv5s
计算机科学, 2024, 51(11A): 231100119-8. <https://doi.org/10.11896/jsjcx.231100119>

[改进YOLOv5s的城市建筑环境下的烟火检测算法](#)

Improved YOLOv5s Algorithm for Detecting Fireworks in Urban Building Environments
计算机科学, 2024, 51(11A): 240100051-7. <https://doi.org/10.11896/jsjcx.240100051>

[融合多尺度特征与位置信息的输电线路山火检测算法](#)

Mountain Fire Detection Algorithm of Transmission Line Based on Multi-scale Features and Coordinate Information
计算机科学, 2024, 51(11A): 230900155-7. <https://doi.org/10.11896/jsjcx.230900155>

[基于YOLOv5s和双稳随机共振的夜间车辆检测算法](#)

Night Vehicle Detection Algorithm Based on YOLOv5s and Bistable Stochastic Resonance
计算机科学, 2024, 51(9): 173-181. <https://doi.org/10.11896/jsjcx.230600056>

[基于MLIR的FP8量化模拟与推理内存优化](#)

FP8 Quantization and Inference Memory Optimization Based on MLIR
计算机科学, 2024, 51(9): 112-120. <https://doi.org/10.11896/jsjcx.230900143>

基于 YOLOv5 的桥梁裂纹检测方法研究

李 军¹ 刘 念² 张世义²

1 重庆交通大学机电与车辆工程学院 重庆 400074

2 重庆交通大学航运与船舶工程学院 重庆 400074

(qleejun@163.com)

摘 要 为解决桥梁裂纹识别中不同裂纹的识别问题,提高模型的拟合能力,并提升裂纹的特征提取能力,提出了一种基于 YOLOv5 融合 EfficientNet,引入 CBAM 注意力机制的桥梁裂纹识别的算法 YOLOv5-Crack。首先,基于网络 EfficientNet 的高精度、高效性,替换 YOLOv5 的特征提取网络以提取裂纹特征;其次,将 CBAM(Convolutional Block Attention Module)卷积块注意力模块与通道和空间注意力模块结合,以增强模型表达浅层目标特征信息的能力,提高了裂纹的识别精度;最后,在桥梁裂缝数据集 Concrete Crack Images for Classification 上训练。研究结果表明:在大型裂纹的识别能力上,YOLOv5-Crack 检测识别精度高于 YOLOv5,其 mAP@0.5,Recall 及 Precision 明显提高,而消耗的算力明显降低,能够满足裂纹的检测要求。

关键词: YOLOv5; EfficientNet; 裂纹识别; CBAM

中图分类号 U448.33

Study on Detection Method of Bridge Crack Based on YOLOv5

LI Jun¹, LIU Nian² and ZHANG Shi-yi²

1 School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074, China

2 School of shipping and Naval Architecture, Chongqing Jiaotong University, Chongqing 400074, China

Abstract To address the issues of different crack recognition in bridge crack identification, improve the model's fitting ability, and enhance crack feature extraction capability, this paper proposes an algorithm called YOLOv5-Crack based on the fusion of YOLOv5 and EfficientNet, incorporating the CBAM attention mechanism in bridge crack recognition. Firstly, the feature extraction network of YOLOv5 is replaced with the EfficientNet network known for its high accuracy and efficiency, to extract crack features. Secondly, the convolutional block attention module (CBAM) is used to enhance the model's ability to capture the feature information of shallow targets by combining channel and spatial attention modules, thereby improving crack recognition accuracy. Finally, the model is trained on the bridge crack dataset "concrete crack images for classification". The research results show that YOLOv5-Crack demonstrates higher accuracy in detecting large cracks compared to YOLOv5, with improved mAP@0.5, recall, and precision. Additionally, it consumes less computing power while meeting the requirements of crack detection.

Keywords YOLOv5, EfficientNet, Crack detection, CBAM

1 引言

桥梁作为道路交通的重要承载体,在日常的使用中会受到天气、承受载荷等影响,表面出现裂痕,甚至破裂,因此桥梁的裂纹识别工作非常重要^[1-2]。裂纹识别在国内外一直是桥梁检测的热门话题。早期的裂纹识别以物理识别性为主,例如超声波检测^[3]、涡流检测^[4-5]、射线检测^[6-7]等。Tang 等^[8]提出了混凝土缺陷的超声红外检测,对混凝土构建进行超声检测,在早期裂纹识别中,探测效果较好;但是在目标较小时存在检测效果不佳与融错问题。Xu 等^[9]基于非线性声场理论,提出边带峰计数法及损伤指标概念对热损伤混凝土微裂纹进行检测,为微裂纹的检测提供了应用价值。在早期未流

行机器学习时,物理识别裂纹的方法是主流的裂纹检测方法,但其存在多目标检测困难、人工检测误差大和工人的安全无法保证问题^[10-11]。

机器学习因具有时效性、高效性和精准性,逐渐取代了传统的人工物理识别检测裂纹方法^[12]。基于机器学习的裂纹识别算法大体分为 3 类:监督学习、无监督学习、强化学习^[12-13]。Li 等^[14]提出了一种新的无监督多尺度融合裂纹检测算法 MFCD,其基于单尺度 WMIP,引入了在不同尺度上检测裂纹的思想,在召回率及精准度上有明显提升,但明暗度较低时算法性能会降低。Zhang 等^[15]提出基于若监督实例分割框架,并引入新的二进制交叉熵损失函数,提高了裂纹识别的精准率,减少了人工标记,但比较容易产生漏检。

基金项目:国家自然科学基金(51305472);城市轨道交通车辆系统集成与控制重庆市重点实验室基金项目

This work was supported by the National Natural Science Foundation of China (51305472) and Chongqing Key Laboratory of Urban Rail Transit Vehicle System Integration and Control Fund Project.

通信作者:刘念 (2424092885@qq.com)

Zhao 等^[16] 基于注意力机制, 并引入混合监督学习对裂纹进行检测, 增强了浅层物理信息的提取, 其检测速度以及精准率有较大提升。基于机器学习的检测方法不仅提升了裂纹检测的精准度, 也大幅度降低了检测成本; 但其存在小目标特征提取能力低及对阴暗部提取能力不够明显的不足, 而卷积神经网络的应用在很大程度上解决了此类问题。

近年来, 卷积神经网络也被广泛用于缺陷检测, 并取得了不错的表现。Teng 等^[17] 基于 YOLOv2 进行裂纹识别研究, 相比于 Resnet18, Alexnet 与 VGG, 其计算时间与精度都更优。Du 等^[18] 提出了基于 YOLO 的 PD 检测和分类的方法, 其不考虑环境干扰, 直接提取环境中的特征, 在强光与光线不足时也能很好识别, 但对阴影部分的识别比较困难。针对复杂背景, 对于有效目标的特征提取问题, Zhu 等^[19] 以 Inception V2 网络代替 Faster RCNN 的卷积层, 提供多尺度图像特征, 获得了更高的识别精准度。Wang 等^[20] 为提高关键特征的提取能力, 引入 CBMA 模块, 通过增强学习特征提高特征提取能力, 并提高多尺度特征融合效率。

由于桥梁裂纹的多样性、环境因素影响, 裂纹检测精度低, 部分裂纹存在漏检、误检问题。针对这些问题, 本文

提出了以 YOLOV5 为主检测网络, 以 EfficientNet 代替 YOLOV5 的特征提取网络, 其在深度、宽度和分辨率方面具有很好的平衡; 在 YOLOv5 主特征提取网络中引入通道与空间注意力机制 CBMA 模块, 以提高网络整体特征提取能力。

2 实施方案

2.1 YOLOV5 检测网络

YOLO^[21] 系列首次于 2015 年提出, 2015 年 YOLOV1 的出现, 开创了 one-stage detection, 相对于 two-stage 的方法, YOLO 在速度和精确度上有了明显提升。2020 年 YOLOV5 提出, 在网络结构上, YOLOV5-s 深度最浅, 速度最快, YOLOV5-x 则反之。本文针对网络的轻量化以及精准度的要求, 选择深度适中、精准度高的 YOLOV5-m。YOLOV5 网络工作原理: 输入特征图, 经自上而下的卷积操作, 从而提取到最后 3 层有效特征层, 再通过自下而上的特征融合得到最后的 3 次有效输出, 有效地提取到高层语义信息和浅层物理信息, 有利于分类和定位, 更充分地提取到物体的特征信息。其网络结构如图 1 所示。

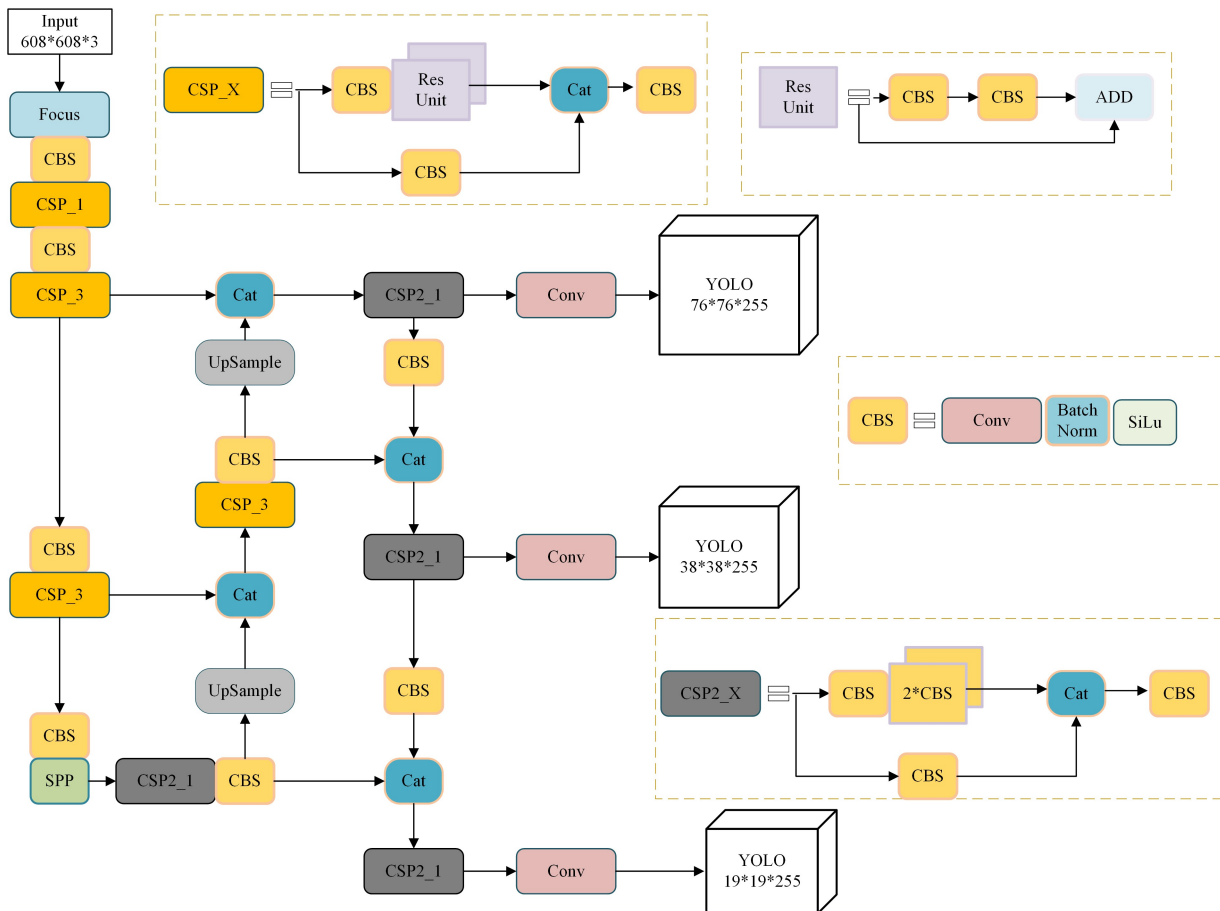


图 1 YOLOV5 网络结构图

Fig. 1 Network structure diagram of YOLOV5

2.2 EfficientNet 特征提取网络

EfficientNet 是一系列的卷积神经网络架构, 包括 EfficientNetB0 到 EfficientNetB7。相对于 B1—B7, B0 网络模型规模更小, 参数量更少, 因此训练速度较与其余版本的 EfficientNet 更快, 且通用性良好。基于桥梁裂纹识别的问题,

选择 EfficientNeBb0^[22] 为主特征提取网络, 它在网络的深度、宽度和分辨率方面具有很好的平衡, 以少的参数量得到更好的识别度, 解决了增加宽度导致的在训练过程中的梯度消失问题, 并提高了更深层次的特征提取, 保障高精度的同时减少了计算量。

EfficientNetB0 结构图如图 2(a)所示,其由 Stem 结构和多个残差块结构堆叠而成,最后以 1×1 的卷积、池化操作和全连接完成特征输出。MBConv 结构如图 2(b)所示,首先对输入的特征图进行一个 1×1 的卷积,进行升维操作,并标准

化;在加激活函数后,进行一次 3×3 或 5×5 的深度可分离卷积,引入 SE 注意力机制模块;然后再接一个 $\text{Conv}1 \times 1$ 普通卷积进行降维操作,进行一次 Dropout 操作,完成特征图融合。

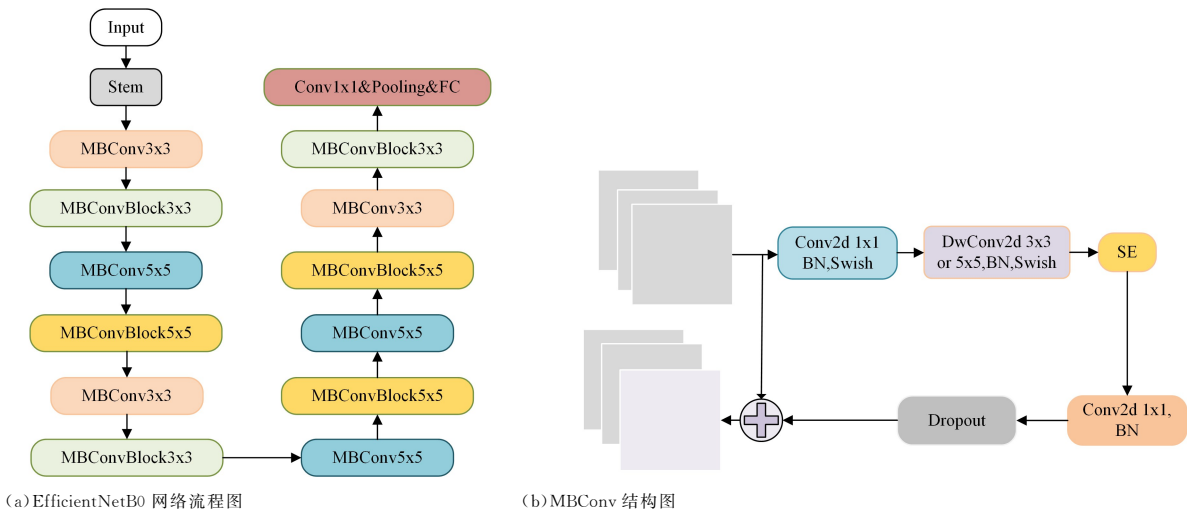


图 2 EfficientNetB0 网络结构图

Fig. 2 Network structure diagram of EfficientNetB0

2.3 CBAM 注意力模块

与 SEnet 通过对通道之间的关系建模提升神经网络表达特征的能力不同,轻量级注意力模块 CBMA 引入通道注意力模块 CAM 与空间注意力模块 SAM,从两个维度产生注意力特征信息,再与原输入特征图相乘进行特征修正,得到特征图^[23]。

(1)CBAM 注意力机制工作原理:给定一个中间特征图 F 作为输入,先对其进行最大池化与平均池化操作,将两个池化层的结果汇入全连接层进行计算,最后相加生成通道

维度上的注意力 M_c ,将 M_c 与输入特征图相乘,得到通道维度调整后的特征图 F' 。再将 F' 在空间上进行最大池化与平均池化操作,将得到的二维向量拼接,最后卷积生成空间注意力 M_s 。其运算过程为:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (1)$$

CBAM 模块生成通道注意力与空间注意力的原理图如图 3 所示。

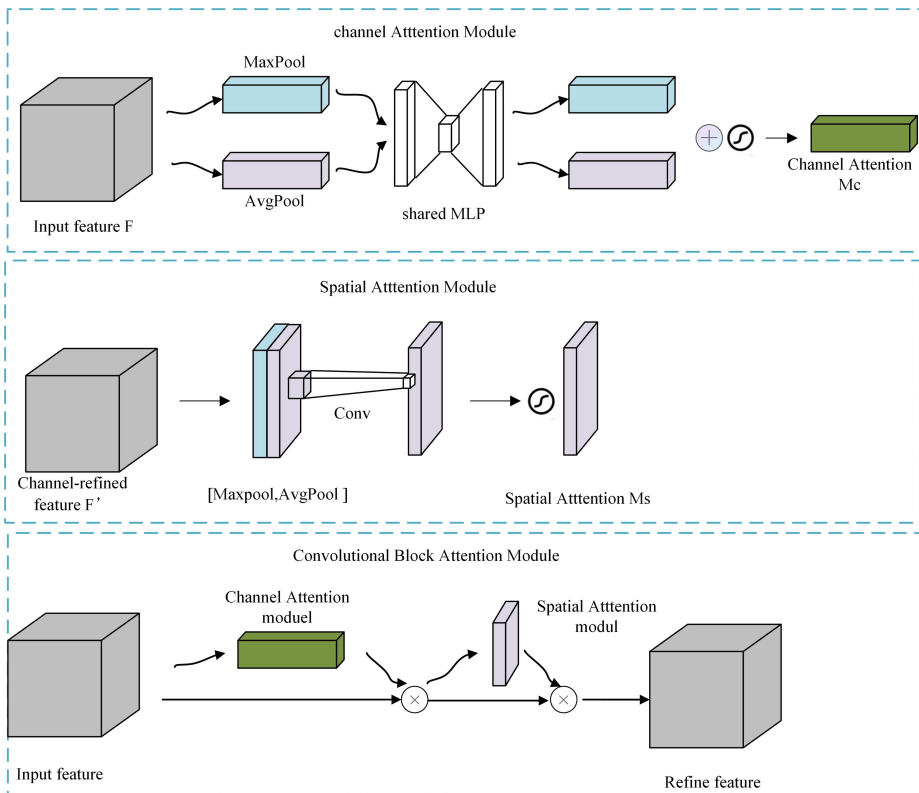


图 3 CBAM 模块原理图

Fig. 3 Schematic of CBAM module

(2)通道注意力模块(CAM):将中间特征 F 分别进行平均池化以及最大池化得到的两个特征图反馈到两个全连接层中,进行相加,再以 sigmoid 函数得到权重系数,最后将权重系数与输入特征图相乘,得到输出特征图。

通道注意力模块计算如式(2)所示:

$$M_C(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ = \sigma(W_1(W_0(F_{\text{avg}}^c))) + W_1(W_0(F_{\text{max}}^c))) \quad (2)$$

(3)空间注意力模块(SAM):同样地,将得到的通道注意力模块 F' 通过最大池化和平均池化进行压缩,得到两个一维特征图,将两个特征图在通道中拼接;再将两个特征图从通道维度拼接,得到一个通道数为 2 的特征图,用单个卷积核的卷积层对其进行卷积操作,使维度与输入的特征图一致。

空间注意力模块计算如式(3)所示:

$$M_S(F) = \sigma(f^{2 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \\ = \sigma(f^{2 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (3)$$

2.4 YOLOV5-Crack 修改后网络结构

YOLOV5-Crack 修改后的网络结构图如图 4 所示,特征提取网络以 EfficientNetB0 主特征提取网络替换 YOLOV5 特征提取网络,在 SPP 模块前引入 CBAM 注意力机制。由于本文算法仅需要 EfficientNetB0 的特征提取部分,而不需要分类,因此删除了 EfficientNetB0 最后的 1×1 卷积层、池化及全连接层,以最后 3 次降维后的输出作为 3 次有效输出特征层,将输出的 3 次特征进行自下而上的特征融合后再输出。

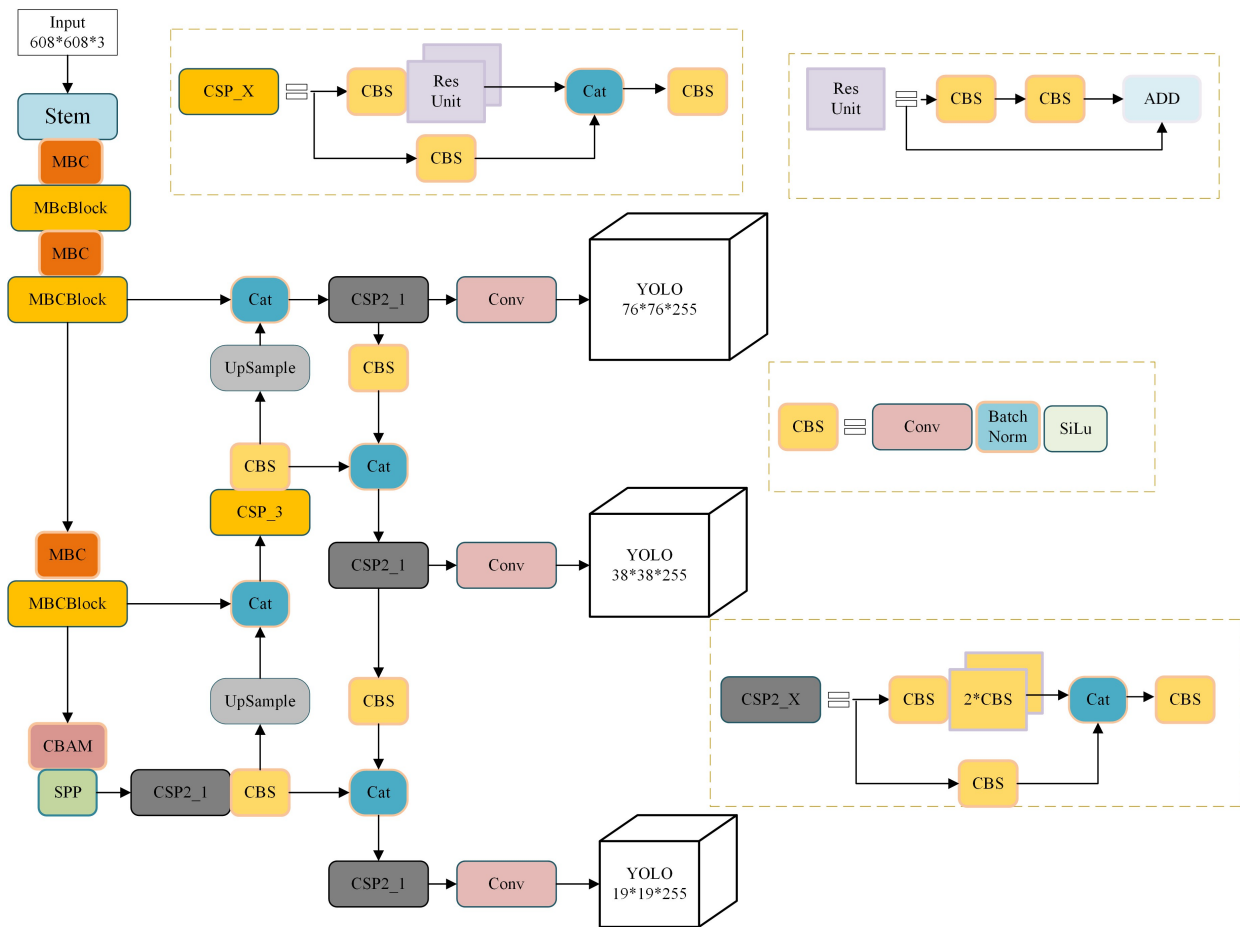


图 4 YOLOV5-Crack 网络结构图

Fig. 4 Network structure diagram of YOLOV5-Crack

3 实验条件

3.1 数据集选取

本文使用 Concrete Crack Imagesfor Classification 数据集,选取其中 1384 张图片,以 9:1 的比例将其划分为训练集及验证集,其中训练集 1245 张,验证集 139 张;使用 Labelimg 标签工具进行标注,将其分为两个类别:Lager Crack(大型裂纹)和 Small Crack(小型裂纹)。

3.2 实验环境及训练

实验操作系统为 Windows10,CPU 型号为 AMD, R7 3700X,GPU 为 GeForce RTX3070,显存大小为 8GB,运行内存为 32GB,Pytorch 版本为 1.7.1,编程语言为 python3.7,CUDA 版本为 11.6。工作主要是针对大型裂纹的识别,为了

得到更好的大型危害性裂纹识别效果,采取修改数据增强方式,mosaic 数据增强参数为 0.5;采用 SGD 优化算法,Batch-size 为 8,Epochs 为 175,GPU 训练,训练次数为 5 次。

3.3 目标检测回归损失函数

损失函数用来衡量模型预测值和真实值的差异度。常见的目标检测回归损失函数有 GIoU,DIoU,CIoU 等。相比 GIoU 和 DIoU,CIoU 考虑了预测框与目标框长宽比的要素,更好地反映了其重叠程度。本文采用 CIoU,其计算如式(4)所示:

$$CIoU = IOU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \quad (4)$$

其中, $\rho^2(b, b^{gt})$ 分别代表预测框与真实框的中心点欧氏距离, c 代表预测框与真实框的最小闭合区域得到对角线的距离, α 为权重函数, v 衡量长宽比的相似度,如式(5)、式(6)所示:

$$\alpha = \frac{v}{1 - IOU + v} \quad (5)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (6)$$

其中, w^{gt} 与 h^{gt} 分别为目标框的长与宽, w 与 h 分别为预测框的长与宽。

4 实验数据及分析

4.1 评价指标

在网络检测精度上,采用通用精度指标:精确度(Precision)、召回率(Recall)和平均精度(mean Average Precision, mAP);通过模型参数量(param)与浮点计算量(Gflops)衡量网络复杂度及算力消耗程度。精确度、召回率、平均精度在机器学习领域和统计分类问题中,常用混淆矩阵表达其关系。

表 1 混淆矩阵

Table 1 Confusion matrix

混淆矩阵	真实值		
	Positive	Negative	
预测值	True	TP	FP
	False	FN	TN

表 1 中, TP 为真阳性, FP 为假阳性, FN 为假阴性, TN 为真阴性。精确度与召回率的计算如式(7)、式(8)所示:

$$precision = \frac{TP}{TP + FP} \quad (7)$$

$$recall = \frac{TP}{TP + FN} \quad (8)$$

模型大小通过 *Param* 网络参数量来恒定, *Param* 越大网络参数越多,训练时内存占据更大。*Gflops* 是实际运算过程中加减乘除的计算次数,代表算力。*Gflops* 越大,算力消耗越大。

4.2 实验结果对比及分析

本文做了两组实验,第一组为 3 种网络的消融实验,分别对 YOLOV5-Efficient(融合 EfficientNetB0 特征提取网络)、YOLOV5-Crack(本文网络)与原有的 YOLOV5 的混凝土桥面裂纹识别能力进行对比。第二组为与主流 YOLO 系列目标识别算法做对比实验。本文算法 YOLOV5-Crack 与 YOLOV5 及 YOLOV5-Efficient 的对比如图 5—图 7 所示。从图 5—图 7 可以看出,替换原版 YOLOV5 网络的主特征提取网络后的 YOLOV5-Efficient 在精确度、召回率上有小幅度提高。从表 2 和表 3 中得出, *mAP@0.5* 提高了 6%, *Recall* 提高了 4.7%, *Precision* 提高了 6%,但算力资源消耗大幅度降低。改进后的模型 YOLOV5-Crack 在精确度、召回率上显著高于原版 YOLOV5 网络。




图 5 mAP@0.5 对比图

Fig. 5 mAP@0.5 comparison




图 6 Precision 对比图

Fig. 6 Precision comparison




图 7 Recall 对比图

Fig. 7 Recall comparison

表 2 模型参数对比

Table 2 Comparison of model parameters

Algorithm	<i>mAP@0.5</i>	<i>Recall</i>	<i>Precision</i>
YOLOV5	60.6	59.1	60.1
YOLOV5-Efficient	63.9	60.0	63.0
YOLOV5-Crack	66.6	63.8	66.1

表 3 模型大小及算力消耗对比

Table 3 Comparison of model size and computing power consumption

Algorithm	Modelsize (params)	GFLPOs (forwardpass)	GPU_men/GB
YOLOV5	20 871 318	385.8	6.233
YOLOV5-Efficient	21 903 799	328.6	4.847
YOLOV5-Crack	22 135 767	336.8	5.037

在类别检测方面,本文主要研究目标为大型裂纹,在特征提取部分主要提升大型裂纹特征提取能力,而适度降低小型非危害性裂纹提取能力。改进后的算法识别对比结果如表 4、表 5 所列, *mAP@0.5* 提高了 15.3%, *Recall* 提高了 12%, *Precision* 提高了 15%。改进后的模型在大裂纹特征提取方面有明显提高,并且降低了非危害性小型裂纹的特征提取概率。

表 4 Large crack 识别参数对比

Table 4 Comparison of large crack recognition parameters

Algorithm	<i>mAP@0.5</i>	<i>Recall</i>	<i>Precision</i>
YOLOV5	69.3	66.4	68.8
YOLOV5-Efficient	70.3	63.1	70.1
YOLOV5-Crack	84.6	78.4	83.8

表 5 Small crack 识别参数对比

Table 5 Comparison of small crack recognition parameters

Algorithm	<i>mAP@0.5</i>	<i>Recall</i>	<i>Precision</i>
YOLOV5	51.9	51.8	51.4
YOLOV5-Efficient	57.5	56.9	55.9
YOLOV5-Crack	48.6	49.2	48.4

表 6 列出了 3 种 YOLO 系列网络的对比实验结果,其中本文算法的 mAP , $Recall$ 和 $Precision$ 均明显高于其余两种算法。


表 6 与部分目标识别网络的对比

Table 6 Comparison with some target recognition networks (%)

Algorithm	$mAP@0.5$	$Recall$	$Precision$
YOLOV5-Crack	66.6	63.8	66.1
YOLOV4	51.3	50.1	48.6
YOLOV3	46.4	45.8	45.1

4.3 检测结果对比分析


为进一步验证本文算法针对大型裂纹的识别能力,选取部分含有大型裂纹和小型非危害性裂纹的图片进行识别,并与 YOLOV5 网络识别进行对比。图 8 给出了本文算法和原版 YOLOV5 的识别对比图,左边为本文算法 YOLOV5-Crack,右边为 YOLOV5 算法。



(a) 单一大型裂纹识别对比



(b) 大小型裂纹误检对比



(c) 大小型裂纹漏检对比

图 8 模型识别对比

Fig. 8 Model recognition comparison

从图 8(a)中可以看出, YOLOV5-Crack 识别单一大型裂纹的能力强于 YOLOV5, YOLOV5 只检测到部分裂纹,而 YOLOV5-Crack 检测到了全部大型裂纹。图 8(b)中 YOLOV5 判断大型裂纹与小型裂纹的能力低于本文算法。图 8(c)中 YOLOV5 存在大量的漏检问题,而本文算法提取到了图片中所有裂纹并识别出对应的裂纹。研究表明:本文 YOLOV5-Crack 算法在检测精度上明显优于 YOLOV5。

结束语 基于原版 YOLOV5 算法在桥梁混凝土桥面大型裂纹识别的检测能力低,提升大型裂纹识别能力的问题,提出了 YOLOV5-Crack 算法。为了在节省网络算力的同时不明显影响网络的复杂程度及精度,并能提高大型裂纹抓取能力,本文提出了一种基于 YOLOV5 的改进模型,以 Efficient-

Net 的主特征提取网络替换 YOLOV5 的主特征提取网络。特征提取网络引入通道与空间注意力机制 CBAM,以加强对大型裂纹的抓取能力,减少模型误检和漏检的问题,并且突出针对大型裂纹的识别精度。实验和测试结果表明: YOLOV5-Crack 算法在精度上明显高于 YOLOV5, $mAP@0.5$ 提高了 6%, $Recall$ 提高了 4.7%, $Precision$ 提高了 6%。类别检测方面,其大裂纹提取能力明显提高, $mAP@0.5$ 提高了 15.3%, $Recall$ 提高了 12%, $Precision$ 提高了 15%, 虽适度降低了小型非危害性裂纹的特征提取能力,但算力资源节省能力强,总体优于 YOLOV5 与未引入 CBAM 注意力机制的 YOLOV5-Efficient 模型。

参考文献

- [1] WANG X Q. Fatigue crack detection and evaluation of steel structure bridges based on AC electromagnetic field detection technology[J]. Industrial Architecture, 2023, 53(8): 102-106.
- [2] LIU X, GAO S W, HE Y. Bridge Crack Detection and Recognition Based on Convolutional Neural Network Transfer Learning [J]. Science and Technology Innovation Herald, 2019(4): 24-25.
- [3] SHAO Z X. Research and Implementation of Concrete Ultrasonic Testing Technology [J]. Vibration, Testing and Diagnosis, 2012, 32(3): 397-401, 513.
- [4] DENG Z Y, KANG Y H, ZHANG J K, et al. Multi-source effect in magnetizing-based eddy current testing sensor for surface crack in ferromagnetic materials[J]. Sensors & Actuators: A. Physical, 2018, 271.
- [5] QUANG T L, NAOYA K, KOUICHI S, et al. Eddy current convergence probes with self-differential and self-nulling characteristics for detecting cracks in conductive materials[J]. Sensors and Actuators: A. Physical, 2023, 349.
- [6] ZHANG X Y, ZHOU B, LI H, et al. Depth detection of spar cap defects in large-scale wind turbine blades based on a 3D heat conduction model using step heating infrared thermography[J]. Measurement Science and Technology, 2022, 33(5).
- [7] DU Y C, ZHANG X M, LI F, et al. Detection of Crack Growth in Asphalt Pavement Through Use of Infrared Imaging[J]. Transportation Research Record Journal of the Transportation Research Board, 2017, 2645: 24-31.
- [8] TANG L, JIANG J P, GU P Y, et al. Experimental study on ultrasonic infrared detection of concrete components[J]. Journal of Hydraulic Engineering, 2012, 43(Z1): 70-75.
- [9] XU Y, ZHANG H Y, WANG Q Y. Experimental study on micro crack detection of heat-damaged concrete based on nonlinear ultrasonic technology[J]. Journal of Vibration and Shock, 2021, 40(5): 126-135.
- [10] NITHIN K, RAVIRAJ V, RENGASWAM Y J. Machine Learning Based Predictions of Fatigue Crack Growth Rate of Additively Manufactured Ti6Al4V[J]. Metals, 2021, 12(1).
- [11] ZHANG L, WANG Z C, WANG L, et al. Machine learning-based real-time visible fatigue crack growth detection[J]. Digital Communications and Networks, 2021, 7(4).
- [12] MIR B A, SASAKI T, NAKAO K, et al. Machine learning-based evaluation of the damage caused by cracks on concrete structures[J]. Precision Engineering, 2022, 76.

- [13] WANG C L, HOU X L, LIU Y B. Three-Dimensional Crack Recognition by Unsupervised Machine Learning[J]. *Rock Mechanics and Rock Engineering*, 2021; 893-903.
- [14] LI H F, SONG D Z, LIUY, et al. Automatic Pavement Crack Detection by Multi-Scale Image Fusion[J]. *IEEE Trans. Intelligent Transportation Systems*, 2019, 20(6).
- [15] ZHANG H C, QIAN Z D, TAN Y F, et al. Investigation of pavement crack detection based on deep learning method using weakly supervised instance segmentation framework[J]. *Construction and Building Materials*, 2022, 358.
- [16] ZHAO C Y, ZHANG H, LIAO D, et al. Rail surface defect detection model based on attention mechanism and mixed supervised learning[J]. *Computer Science*, 2022, 49(S2): 488-493.
- [17] TENG S, LIU Z, CHEN G, et al. Concrete Crack Detection Based on Well-Known Feature Extractor Model and the YOLO_v2 Network[J]. *Applied Sciences*, 2021, 11(2): 813.
- [18] DU Y C, PAN N, XU Z H, et al. Pavement distress detection and classification based on YOLO network[J]. *International Journal of Pavement Engineering*, 2020(1): 1-14.
- [19] ZHU X, ZHU M, REN H. Method of plant leaf recognition based on improved deep convolutional neural network[J]. *Cognitive Systems Research*, 2018, 52(DEC.): 223-233.
- [20] WANG M, WANG K, LI S, et al. Pill detection algorithm based on improved EfficientDet[J]. *Electronic Measurement Technology*, 2022, 45(19): 136-142.
- [21] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only Look Once: Unified, Real-Time Object Detection[C]// *Computer Vision & Pattern Recognition*. IEEE, 2016.
- [22] TAN M X, LE Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks[J]. *arXiv*; 1905. 11946, 2019.
- [23] ZHANG S, LIU Z, CHEN Y, et al. Selective kernel convolution deep residual network based on channel-spatial attention mechanism and feature fusion for mechanical fault diagnosis[C]// *ISA Transactions*. 2022.



LI Jun, born in 1964, Ph.D, professor, master's supervisor. His main research interests include energy saving and new energy vehicles and their applications, intelligent vehicle perception, decision-making and control, automobile engine combustion emissions and control, advanced manufacturing technology and application.



LIU Nian, born in 1999, postgraduate. His main research interests include bridge damage crack identification and detection, and so on.