

改进YOLOX的桥梁病害检测识别

廖延娜 姚亮

Bridge disease detection and recognition based on improved YOLOX algorithm

LIAO Yanna, YAO Liang

引用本文:

廖延娜, 姚亮. 改进YOLOX的桥梁病害检测识别[J]. 应用光学, 2023, 44(4): 792–800. DOI: 10.5768/JAO202344.0402004

LIAO Yanna, YAO Liang. Bridge disease detection and recognition based on improved YOLOX algorithm[J]. Journal of Applied Optics, 2023, 44(4): 792–800. DOI: 10.5768/JAO202344.0402004

在线阅读 View online: <https://doi.org/10.5768/JAO202344.0402004>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进SSD的车辆小目标检测方法

Detecting method of small vehicle targets based on improved SSD

应用光学. 2020, 41(1): 150–155 <https://doi.org/10.5768/JAO202041.0103004>

基于双路多尺度金字塔池化模型的显著目标检测算法

Salient target detection algorithm based on dual-channel multi-scale pyramid pooling model

应用光学. 2021, 42(6): 1056–1061 <https://doi.org/10.5768/JAO202142.0602007>

基于改进YOLOv3网络的无人车夜间环境感知

Nighttime environment perception of driverless vehicles based on improved YOLOv3 network

应用光学. 2019, 40(3): 380–386 <https://doi.org/10.5768/JAO201940.0301004>

基于视觉SLAM和目标检测的语义地图构建

Semantic SLAM based on visual SLAM and object detection

应用光学. 2021, 42(1): 57–64 <https://doi.org/10.5768/JAO202142.0102002>

批量高速二维码视觉检测识别系统

Identification system for batch of two-dimensional code with high speed based on machine vision

应用光学. 2021, 42(2): 276–282 <https://doi.org/10.5768/JAO202142.0202004>

大口径光学元件表面疵病在位检测与评价研究

In situ detection and evaluation of surface defects for large-aperture optical elements

应用光学. 2019, 40(6): 1167–1173 <https://doi.org/10.5768/JAO201940.0605005>



关注微信公众号, 获得更多资讯信息

文章编号: 1002-2082 (2023) 04-0792-09

改进 YOLOX 的桥梁病害检测识别

廖延娜, 姚 亮

(西安邮电大学 电子工程学院, 陕西 西安 710121)

摘 要: 针对目前基于卷积神经网络的桥梁病害检测算法准确度较低的问题, 提出一种改进的 YOLOX 算法来提高检测的精度。通过使用主干网络浅层的特征信息, 改进了特征提取加强网络, 并且加入了同层的特征信息进行融合; 引入改进的坐标注意力机制, 将位置信息和通道信息结合起来增强网络对桥梁病害的识别; 同时对定位损失函数进行了改进。实验结果表明: 改进的 YOLOX 网络结构对于桥梁病害检测的准确度达到 92.11%, 比原网络提高了 4.40%。

关键词: 目标检测; 病害检测; YOLOX; 图像处理

中图分类号: TN957.52; TP391

文献标志码: A

DOI: 10.5768/JAO202344.0402004

Bridge disease detection and recognition based on improved YOLOX algorithm

LIAO Yanna, YAO Liang

(School of Electronic Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

Abstract: In view of the low accuracy of the current bridge disease detection algorithm based on convolutional neural network, an improved YOLOX algorithm was proposed to improve the detection accuracy. By using the feature information of the shallow layer of the backbone network, the feature extraction enhancement network was improved, and the feature information of the same layer was added for fusion. An improved coordinate attention mechanism was introduced to combine the position information and the channel information to enhance the network recognition of bridge diseases. At the same time, the localization loss function was improved. The experimental results show that the accuracy of the improved YOLOX network structure for bridge disease detection reaches 92.11%, which is 4.40% higher than the original network.

Key words: target detection; disease detection; YOLOX; image processing

引言

随着我国经济和综合国力的发展, 桥梁建设的规模日益扩大。截至 2020 年末^[1] 全国公路桥梁 91.28 万座, 比上年末增加 3.45 万座。桥梁使用过程中的外力作用和自然老化会导致出现多种表面病害, 及时准确发现桥梁存在的病害对桥梁安全运行意义重大。无损检测通过使用红外线、超声波等技术, 在不破坏被测物的情况下, 获取被测物的损伤信息。无损检测技术应用于桥梁病害检测和诊断^[2], 存在检测区域受限问题。人工使用刻度尺等测量仪器直接对桥梁表面病害进行测量, 存在测量精度不高和漏检问题; 采用无人机拍摄桥

梁图片, 人工进行病害评估, 提高了桥梁病害的检测效率。但是随着桥梁总体量的增加, 人工检测方法的缺点将进一步放大^[3], 如工作量不断增大、效率越变越低等。

为了解决上述传统方法的局限性, 采用深度学习中的卷积神经网络(convolutional neural networks, CNN)对大量的桥梁病害图像数据^[4] 进行处理, 提取图像特征, 最后获得目标病害位置及类别的方法, 成为桥梁表面病害智能化检测的研究热点。2019 年, 张宁^[5] 采用了 FasterR-CNN 方法进行道路病害的检测, 采用了 Soft-NMS 方法取代了原有 NMS(non-maximum suppression)方法, 减少了道路

收稿日期: 2022-07-07; 修回日期: 2023-04-04

基金项目: 陕西省重点研发计划-国际科技合作计划项目(2020KW-001); 西安市科技计划项目合同书-西安市创新能力强基计划(21XJZZ0074)

作者简介: 廖延娜(1974—), 女, 硕士, 副教授, 主要从事信号与信息处理、图像处理与深度学习研究。E-mail: liaoyan@xupt.edu.cn

通信作者: 姚亮(1997—), 男, 硕士研究生, 主要从事机器学习、深度学习与图像处理研究。E-mail: 3463665527@qq.com

病害的漏测率,同时提升了对裂纹和坑沟等二类病害的测量精度,平均准确度为 88.3%。2019 年, ZHANG C^[6] 等人采用 YOLOv3 算法检测病害图像,包含的病害类型有露筋、裂缝、保护层脱落、剥落,对病害的分类准确度为 80%。2021 年,罗晖等^[7] 使用改进的 YOLOv4 算法检测路面病害图像,病害主要包括横向裂缝、纵向裂缝、网状裂缝和坑槽,方法是替换网络层中原始卷积结构,针对样本不平衡问题使用 focal-loss 改进损失函数,检测精度为 93.64%。2022 年,周清松等^[8] 采用改进的 YOLOv3 对桥梁表面病害做检测,包含 4 种病害类型,即露筋、风化、腐蚀污点、剥落,通过在检测层中加入固定大小的池化模块,让局部特征和全局特征融合,将模型对病害的检测精度提高为 85.6%。

用于目标检测的卷积神经网络算法^[9] 有 2 个类别:二阶段目标检测算法和单阶段目标检测算

法。二阶段目标检测算法有 R-CNN、FastR-CNN 及 MaskR-CNN 等算法,单阶段目标检测算法有 SDD(single shot multibox detector) 以及 YOLOv3、YOLOv4、YOLOV5、YOLOX(you only look once X) 等。YOLO 系列的网络是直接回归检测,YOLOX^[10] 的检测效果超越之前的 YOLO 系列模型,在检测精度上更准确。针对目前使用深度学习算法对桥梁病害检测,存在准确度较低的问题,本文使用 YOLOX 模型为基础,对桥梁病害进行检测,为了提高网络对病害的检测精度,对其网络结构加以改进,使得网络能提高桥梁病害检测的精度。

1 YOLOX 网络算法

1.1 YOLOX 网络介绍

YOLOX 算法整体的网络结构如图 1 所示,网络一共包括 3 大部分。




图 1 YOLOX 网络结构及子模块图

Fig. 1 YOLOX network structure and sub-module diagram

第 1 部分是主干网络 CSpdark53。它是在 darknet^[11] 中增加 (cross stage partial, CSP) 结构,原始图片输入到 CSpdark53 网络中,首先将图片尺寸调整成 $640 \times 640 \times 3$ 像素,经过 Focus 结构,通过对图像切片和拼接将高和宽进行压缩,使得通道数加倍,尺寸变为 $320 \times 320 \times 12$ 像素,之后进行卷积标准化和激活函数进行特征提取。CSpdark53 有 4 个残差结构,均分别进行 3×3 卷积下采样,压缩高和宽,改变

通道数,通过 CSP 结构进行特征提取, SPP(spatial pyramid pooling)^[12] 将空间金字塔池化作为特征提取网络的最后一层,主要目的是分离上下文特征,增加感受野,通过不同大小池化核进行最大池化来提取特征。

第 2 部分是颈部(neck),也叫特征提取加强网络。从主干网络获取 3 个有效的特征层,尺寸分别是 80×80 像素、 40×40 像素和 20×20 像素,其中深

层特征图经过 1×1 的卷积来调整通道数并进行卷积上采样;再将输出特征图与相邻的浅层特征图拼接,之后经过 CSP 层进行特征提取;最终,颈部结构输出不同尺寸的特征图。

第3部分是检测头(detection head)。经过检测头输出3个尺寸的特征图 20×20 像素、 40×40 像素、 80×80 像素。YOLOX 检测头将类别和回归框分开预测,每一个特征层会有3个预测结果。

1.2 YOLOX 网络改进

1.2.1 改进颈部结构

YOLOX 网络的颈部结构由两部分组成:FPN(feature pyramid networks)结构是从上到下进行特征提取,深层特征图经过上采样与浅层特征图做特征融合得到新的特征图;PAN(pyramid attention network)结构则与 FPN 相反,进行从下到上的特征提取。

深度特征图通常具有更多的语义特征和更少的边缘信息。浅层特征图具有较强的边缘信息和较少的语义信息。FPN 的作用是从深到浅发送丰富的语义信息,以增强模型的语义信息;PAN 的作用是将浅层的边缘信息发送到深层,以增强对模型的定位能力。

在 EfficientDet^[13] 网络中,提出了双向特征金字塔网络,其结构如图2所示。BiFPN 结构采用双向融合的思想,不仅是从上层到下层、从下层到上层的特征融合,而且不同尺寸的特征图进行特征融合后,在同一尺寸上添加横向连接,解决网络层

数多导致的信息缺失。




图2 BiFPN 结构

Fig. 2 Structure diagram of BiFPN

YOLOX 的主干网络输出给颈部网络3个特征层的特征图。但随着特征图层数越来越深,提取的边缘信息越少。为了更好地让模型对桥梁病害的边缘特征进行识别,本文提出融合浅层特征的方法,具体如下:将 YOLOX 主干网络的 dark3 特征图在 CSP 层处理后,增加一个浅层融合模块,该模块由上层卷积上采样后与 dark2 层提取的特征图拼接,经过 CSP 操作进行特征提取,通过卷积进行下采样,最后将输出的特征图与该层相同尺寸的特征图进行拼接,并将获得的特征图输出给后面的检测头网络。

改进理由是由于 YOLOX 网络的 FPN 和 PAN 结构之间特征融合,大多数纵向方向的连接,随着网络层数变多会导致信息缺失,不能很好地将信息进行融合,因此在不同尺寸特征图特征融合后,改进原始的结构。在最后一层上,添加同一尺寸上横向连接,增加横向方向的特征融合,使得网络把语义特征和定位信息联系起来。其中融合浅层特征的网络改进如图3中虚线连接所示。




图3 改进的 YOLOX(增加横向连接、浅层融合模块)

Fig. 3 Improved YOLOX (increased lateral connections and shallow fusion module)

1.2.2 CA 模块的构建

由于 YOLOX 中特征加强网络在进行特征融合时, 采用了直接拼接的方式; 然而因为不同的输入特征图对融合后输出特征的贡献是不平等的, 因此提出改进方法, 本文考虑引入通道注意力机制, 能更好地适应不同层网络结构对输出的贡献。

通道注意力机制可以强化有效信息, 减小干扰。常用的通道注意力模块有 SE(squeeze-and-excitation)、CBAM(convolutional block attention module) 等。SE 模块^[14]直接将特征图转换为特征向量, 只考虑通道间信息的编码, 丢失了位置信息; CBAM^[15]采用全局池化来引入位置信息, 但是位置信息不精细。

坐标注意机制 (coordinate attention, CA) 模块是一种高效的注意力机制, 将空间的详细位置信息和通道注意力结合。CA^[16]模块通过两个步骤完成位置信息的嵌入和注意力生成, 其模型结构如图 4 所示。




图 4 CA 模块结构

Fig. 4 Structure diagram of CA module

首先将详细位置信息嵌入模块中, 转换为一对一维度的编码操作。通过尺寸为 $(H, 1)$ 和 $(1, W)$ 的全局池化, 进行水平方向和竖直方向通道编码, 获取详细的位置信息。上述两个 1 维的全局池化在得到一个方向位置信息的同时, 保存了另一个方向上的持续依赖。然后, 通过 1×1 的卷积来压缩维度, 并在批量归一化后经过激活函数, 再将特征图还原为原始的通道数, 得到输入特征图的两个维度上的注意力权重, 最后通过乘法获得具有两个方向上注意力权重的特征图。

CA 模块中使用的激活函数 sigmoid 的输出是

一个介于 0 和 1 之间的值, 该激活函数收敛速度较慢, 且其输出均值不为 0。在网络训练的过程中, 数据需要通过归一化等预处理来达到 0 均值。

为了提高模型的收敛速度, 便于网络训练, 本文将对 CA 模块中的激活函数进行改进: 采用 0 均值的 tanh 函数替代 sigmoid 函数。图 5 为 tanh 函数和 sigmoid 函数曲线, 由图中两函数的导数可以看出, tanh 函数的导数比 sigmoid 函数导数值更大, 梯度下降更快, 所以在网络训练中收敛速度更快; 且 tanh 函数均值为 0。




图 5 sigmoid 和 tanh 激活函数

Fig. 5 Activation function curves of sigmoid and tanh

本文在 YOLOX 的特征提取加强网络中引入上述改进后的 CA 模块, 以提高网络的识别精度。改进的 CA 模块在嵌入网络结构中的位置见图 3。

1.2.3 损失函数的改进

YOLOX 中的损失函数是各个分支损失的加权重。由于原始的 YOLOX 网络中的定位损失函数 IoU(intersection over union) 对于定位存在缺陷, 因此替换原始的定位损失函数为 CEIoU(complete efficient-IoU), 这样能更好地检测出病害, 提高检测精度。

$$L_{\text{loss}} = L_{\text{reg}} + L_{\text{obj}} + L_{\text{cls}} \quad (1)$$

式中: L_{reg} 用来预测特征点对应的回归参数; L_{obj} 用来判断特征点是否包含物体; L_{cls} 用来判断特征点包含的种类。把 3 个预测结果堆叠, 能得到每个特征图的结果。

定位损失 L_{reg} 是预测边界框和真实框的误差。常见的定位损失算法包括: IoU、GIoU(generalized-IoU)、DIoU(distance-IoU)、CIoU(complete-IoU) 和 EIoU(efficient-IoU)。IoU 是真实框与预测框的交集面积和并集面积的比值, 当真实框与预测框没有交集时, IoU 为 0, 网络无法进行反向传播学习。GIoU 不仅关注两框的重叠区域, 还关注非重叠区域。DIoU 引入惩罚项为两框的中心点欧氏距离的

比值。CIoU 和 EIou 是为了让预测框更加接近真实框, CIoU 引入同一个框的纵横比, EIou 将两框的长宽边的真实差作为新的惩罚项。为了使得网络的定位更加的准确, 对定位损失函数做改进, 提出替换原始 IoU 为 CEIoU 损失函数。CEIoU 的公式如下:

$$C_{EIou} = I_{ou} - \frac{\rho^2(b, b_{gt})}{c^2} - \frac{\rho^2(w, w_{gt})}{c_w^2} - \frac{\rho^2(h, h_{gt})}{c_h^2} - \alpha v \quad (2)$$

$$\alpha = \frac{v}{(1 - I_{ou}) + v} \quad (3)$$

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

式中: w 表示真实框的宽; h 表示真实框的高; w_{gt} 表示预测框的宽; h_{gt} 表示预测框的高; v 描述两个框长宽比的相似性; α 是权重系数。

CEIoU 损失函数有 3 个部分: 对重叠区域的损失、对两框距离的损失以及对两框的宽高损失。

IoU 是真实框与预测框的交集面积与并集面积比值。针对重叠区域的损失, 是计算两框交集面积与并集面积比值; 针对两框的距离损失, 是计算两框中心点间的欧式距离平方和与两框外围最大矩形对角边平方的比值; 针对两框的宽高损失由两部分组成, 一部分是两框各自长宽比损失, 另一部分是两框间长或宽的真实差的平方和与两框中最大的长或宽平方和的比值。改进后的损失函数能很好地反映出两框间的损失, 也能加快收敛速度。

2 网络模型训练及准备数据集

2.1 实验环境与数据集

本文实验硬件配置为 NVIDIA GeForce GTX 1070-Ti 显卡, CUDA 版本为 10.1 cudnn 版本为 7.6, 利用的深度学习框架为 Pytorch 1.7。网络训练的参数如表 1 所示。

表 1 参数的初始化

Table 1 Initialization of parameters

输入图片尺寸/像素	优化器	动量系数	冻结次数	批量大小	学习率	解冻次数	批量大小	学习率	总次数
640×640	Adam	0.8	50	16	0.001	200	8	0.0001	250

本次实验使用混凝土缺陷桥梁图像数据集^[17], 数据集中的表观病害分为 5 类, 即裂缝、剥落、风化、漏筋和腐蚀污点。图 6 展示了训练集图片中各种病害的形态和特点, 图 6(a)有腐蚀污点, 可以

看出它锈迹斑斑, 不同于其他墙面; 图 6(b)有裂缝病害; 图 6(c)有风化的病害, 它表现为白色, 片状分布; 图 6(d)有剥落和露筋的混合病害, 剥落是混凝土脱落的结果, 最后也可能会形成钢筋外露, 使得多种病害在同一个位置。

对基础数据进行可视化分析, 发现有部分图片的病害目标框在图片尺寸的外侧, 因此去除错误框, 一共得到了 1016 张图片, 并对图片做同比例的缩放。对数据集进行扩充, 扩增方式包括图片模糊、翻转和亮度调整, 最终获得 3048 张新图片, 训练集和测试集比例为 9 : 1。通过对训练集的 XML (extensible markup language) 文件进行解析, 获得本次研究各种桥梁表观病害的数目, 统计后的各种病害数目如表 2 所示。




图 6 部分训练集病害图片

Fig. 6 Part of disease images in training set

表 2 训练集中各种病害框数目

Table 2 The number of various diseases in training set

各种病害	风化	裂缝	露筋	剥落	腐蚀污点	总计
训练集病害框数目	2579	8259	4866	6173	4971	26848

2.2 评价指标

混淆矩阵如表 3 所示: 将所有的样本分成 4 个类型, 将正样本检测为正样本是 TP, 将正样本检测

为反样本是 FN, 将反样本检测为正样本是 FP, 将反样本检测为反样本是 TN。所有预测正确的样本数总数是 TP 和 TN 之和, 所有预测为正样本的样本总数是 TP 和 FP 之和。TP 和 FN 是所有实际为正的样本。

表 3 混淆矩阵
Table 3 Confusion matrix

混淆矩阵		真实值	
		正例	反例
预测值	正例	真正例	假正例
	反例	假反例	真反例

精确度 P 指所有正确被预测的正样本占预测为正样本的百分比, 召回率 R 指所有正确被预测

的正样本占有所有正样本的百分比, MAP 是所有类的平均准确率之和除以类数。

3 实验结果与分析

3.1 网络的消融实验

将多个模型的实验数据进行对比, 其中使用到的模型包括: 基础 YOLOX 模型; 不修改损失函数, 改进 YOLOX 网络颈部结构, 修改 CA 模块后的 YOLOX-b 模型; 在 YOLOX 网络的基础上, 只修改为 CEIoU 损失函数的 YOLOX-aa 模型; 在 YOLOX-b 模型的基础上, 修改为 EIoU 损失函数的 YOLOX-c 模型; 修改为 CEIoU 损失函数的 YOLOX-d 模型; 并使用 YOLOV-5 算法做了实验。实验结果如表 4 所示, 训练过程中的损失函数曲线如图 7 所示。

表 4 改进的 YOLOX 和 YOLOX 的实验结果

Table 4 Experimental results of improved YOLOX and YOLOX

算法	平均精度/%					平均精度均值/%
	风化	裂缝	漏筋	腐蚀污点	剥落	
原YOLOX	82.80	77.77	94.57	90.01	93.19	87.67
YOLOX-aa	82.89	82.15	94.72	90.02	93.37	88.63
YOLOX-b	86.25	83.31	96.35	91.74	93.42	90.22
YOLOX-c	85.39	86.14	96.53	92.49	95.34	91.18
YOLOX-d	88.67	85.91	97.07	93.10	95.78	92.11
YOLOV-5	82.54	79.01	74.67	66.71	78.69	76.32




图 7 损失曲线

Fig. 7 Loss curves

从表 4 可以看出, 改进后的 YOLOX-d 算法精确度高于基础 YOLOX 算法, 平均精度均值从 87.67% 提高至 92.11%, 整体提升 4.4%, 针对裂缝和风化病害的检测精度, 分别提升 8.14%, 5.87%,

也提高了对其他桥病害的检测精度。YOLOX-aa 模型相比基础 YOLOX 网络, 在替换为 CEIoU 定位损失函数后, 提高模型对病害的定位能力, 最为突出的是对裂缝病害的识别度提高了 4.38%。

由于引入浅层的特征, 包含的边缘信息较多, 因此改进的YOLOX-b模型比基础YOLOX网络对风化和裂缝的检测性能更强, 检测精度分别提高3.45%和5.5%, 对于其他细小病害的识别准确度也有提高。而基础YOLOX算法比YOLOV5算法对各种病害的平均检测精确度都高, 证明了选取初始算法的有效性和健壮性。

训练过程中, 生成的损失函数曲线如图7所示。图7中横坐标是训练次数, 纵坐标是损失值, 可以看出改进的YOLOX-d模型生成的损失曲线在曲线图的下方, 通常损失曲线越低, 模型检测准确度会更高, 对病害的检测效果更好, 且改进损失函数后模型收敛速度更快。

此外, 对其他研究者提出的桥梁病害算法也做了对比, 周青松等人基于YOLOV3算法做了改进, 并对桥梁数据集中4种病害进行了检测, 对比结果如表5所示。

从表5可以看出: 改进的YOLOX算法对比YOLOV3, 对各种病害的检测精度, 除了对剥落病害检测有些下降外, 其他的病害检测精度明显提

高, 显示了对算法改进后的优势。

表5 将改进算法与其他研究者提出算法对比

Table 5 Comparison of improved algorithm with those proposed by other researchers

算法	平均精度/%					平均精度均值/%
	风化	剥落	漏筋	腐蚀污点	裂缝	
YOLOX-d	88.67	85.91	97.07	93.10	95.78	92.11
改进YOLOV3	81.4	86.0	89.2	85.6	—	86.6

3.2 图片检测的可视化

使用基础YOLOX网络与改进的YOLOX-d网络对测试集图片进行可视化对比。如图8左侧为使用基础YOLOX网络的结果, 右侧为改进的YOLOX-d网络的检测结果, 图8(a)的病害为露筋和腐蚀污点。根据图中检测病害效果看, 图8(b)检测出左上图没有检测出的多个露筋病害, 对于图8(c)、图8(d)两个图, 改进后的YOLOX-d网络检测出基础网络没有检测出的风化病害, 并提高整体对裂缝识别的精确度。




图8 可视化改进前后对比

Fig. 8 Comparison before and after visualization improvement

4 结论

目前对于桥梁表面病害的检测任务, 存在检测精确度低、召回率低的问题, 本文提出一种改进的 YOLOX 算法, 首先对原始桥梁数据集进行扩充, 提高网络模型的泛化性; 其次对 YOLOX 网络颈部结构进行改进, 通过引入浅层的特征信息, 加入了同样尺寸的特征层信息进行融合; 加入改进的坐标注意力机制 CA 模块, 把位置信息和通道信息更深层地结合起来增强网络对桥梁病害的识别; 此外, 提出使用 CEIoU 定位损失函数, 优化网络模型。最终, 实验结果表明, 改进的网络对桥梁的病害有更高的检测精度。

参考文献:

- [1] 卢文壮, 郑宗雨, 赵文茹, 等. 中国桥梁发展与标准化[J]. 标准科学, 2021(增刊1): 240-246.
LU Wenzhuang, ZHENG Zongyu, ZHAO Wenru, et al. Development and standardization of bridges in China[J]. Standard Science, 2021(S1): 240-246.
- [2] 贾潇宇. 基于卷积神经网络的桥梁裂缝识别与测量方法研究[D]. 柳州: 广西科技大学, 2019.
JIA Xiaoyu. Research on bridge crack identification and measurement method based on convolutional neural network[D]. Liuzhou: Guangxi University of Science and Technology, 2019.
- [3] 杨建华, 邹俊志. 基于机器学习的RC桥梁病害检测方法[J]. 北方交通, 2020(6): 18-20.
YANG Jianhua, ZOU Junzhi. RC bridge disease detection method based on machine learning[J]. North Traffic, 2020(6): 18-20.
- [4] 杨紫艳, 马龙博, 邓凌, 等. 基于卷积神经网络的桥梁裂缝检测研究[J]. 山西建筑, 2021, 47(19): 131-133.
YANG Ziyan, MA Longbo, DENG Ling, et al. Research on bridge crack detection based on convolutional neural network[J]. Shanxi Architecture, 2021, 47(19): 131-133.
- [5] 张宁. 基于Faster R-CNN的公路路面病害检测算法的研究[D]. 南昌: 华东交通大学, 2019.
ZHANG Ning. Research on highway pavement disease detection algorithm based on Faster R-CNN[D]. Nanchang: East China Jiaotong University, 2019.
- [6] ZHANG C, CHANG C, JAMSHIDI M. Concrete bridge surface damage detection using a single stage detector[J]. Computer Aided Civil and Infrastructure Engineering, 2020, 35(4): 389-409.
- [7] 罗晖, 贾晨, 李健. 基于改进YOLOv4的公路路面病害检测算法[J]. 激光与光电子学进展, 2021, 58(14): 336-344.
LUO Hui, JIA Chen, LI Jian. Highway pavement disease detection algorithm based on improved YOLOv4[J]. Advances in Laser and Optoelectronics, 2021, 58(14): 336-344.
- [8] 周清松, 董绍江, 罗家元, 等. 改进YOLOv3的桥梁表面病害检测识别[J]. 重庆大学学报, 2022, 45(6): 121-130.
ZHOU Qingsong, DONG Shaojiang, LUO Jiayuan, et al. Improved YOLOv3 for bridge apparent disease detection and identification[J]. Journal of Chongqing University, 2022, 45(6): 121-130.
- [9] 陈先昌. 基于卷积神经网络的深度学习算法与应用研究[D]. 杭州: 浙江工商大学, 2014.
CHEN Xianchang. Research on deep learning algorithm and application based on convolutional neural network [D]. Hangzhou: Zhejiang Gongshang University, 2014.
- [10] 陆绮荣, 丁昕. 一种基于改进YOLOX的地下排水管道缺陷检测识别方法[J]. 电子测量技术, 2022, 45(21): 161-168.
LU Qirong, DING Xin. An improved YOLOX-based method for defect detection and identification of underground drainage pipelines [J]. Electronic Measurement Technology, 2022, 45(21): 161-168.
- [11] WANG C Y, LIAO H, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). New York: IEEE, 2020.
- [12] 蔡伟, 徐佩伟, 杨志勇, 等. 复杂背景下红外图像弱小目标检测[J]. 应用光学, 2021, 42(4): 643-650.
CAI Wei, XU Peiwei, YANG Zhiyong, et al. Detection of weak and small targets in infrared images under complex background[J]. Journal of Applied Optics, 2021, 42(4): 643-650.
- [13] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. New York: IEEE, 2020: 10781-10790.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE, 2018: 7132-7141.
- [15] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional

- block attention module[C]//Proceedings of the European conference on computer vision (ECCV). New York: IEEE, 2018: 3-19.
- [16] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2021: 13713-13722.
- [17] MUNDT M, MAJUMDER S, MURALI S, et al. Meta-learning convolutional neural architectures for multi-target concrete defect classification with the concrete defect bridge image dataset[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2019: 11196-11205.