

基于 YOLOX-GED 的路面病害检测算法^{*}封淑玲¹ 王 琪² 吕成伊²

(1.南昌工学院信息与人工智能学院 南昌 330108; 2.南昌大学信息工程学院 南昌 330036)

摘 要: 路面病害检测在道路养护中尤为重要,针对路面病害检测存在路面图像背景复杂、病害尺度差异大等问题,提出了 YOLOX-GED 算法,该算法在 YOLOX-s 算法的基础上,首先设计 CSP_Ghost 模块替换 CSPLayer 模块,减少网络参数量的同时加强了网络的特征提取能力;其次,引入 ECA 注意力机制,加强了网络的特征融合效果,提高了网络对路面病害的识别精度;最后,设计 DSPPF 空间金字塔结构,增加特征的多样性,加强了对多尺度上下文信息的提取融合。在 RDD2020 数据集上进行实验,结果表明,YOLOX-GED 算法的 mAP 比 YOLOX-s 算法高出 5.32%,同时模型参数量减少了 7.9%,更易部署到移动设备。

关键词: 目标检测;路面病害检测;YOLOX;Ghost 模块;注意力机制

中图分类号: TP391.4;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Pavement disease detection algorithm based on YOLOX-GED

Feng Shuling¹ Wang Qi² Lyu Chengyi²

(1. School of Information and Artificial Intelligence, Nanchang Institute of Science & Technology, Nanchang 330108, China;

2. School of Information Engineering, Nanchang University, Nanchang 330036, China)

Abstract: Pavement disease detection is particularly important in road maintenance, and the YOLOX-GED algorithm is proposed for the problems of complex background of pavement image and large difference of disease scale in pavement disease detection. On the basis of YOLOX-s algorithm, the algorithm firstly designs CSP_Ghost module to replace CSPLayer module, which reduces the number of network parameters and at the same time strengthens the feature extraction ability of the network; secondly, introduces the ECA attention mechanism, which strengthens the feature fusion effect of the network, and improves the recognition accuracy of the network on the pavement lesions; lastly, designs the pyramid structure of DSPPF space, which increases the diversity of features and strengthens the recognition accuracy of the network on the pavement lesions. that increases the diversity of features and strengthens the extraction and fusion of multi-scale contextual information. Experiments on the RDD2020 dataset show that the mAP of the YOLOX-GED algorithm is 5.32% higher than that of the YOLOX-s algorithm, and at the same time, the amount of model parameters is reduced by 7.9%, which makes it easier to deploy to mobile devices.

Keywords: object detection; pavement defect detection; YOLOX; Ghost module; attention mechanism

0 引 言

路面病害是指水泥或者沥青路面出现的各种损坏、变形及其他缺陷,这些病害不仅影响行车的舒适性,甚至可能威胁行车安全。传统的路面病害检测,依靠工作人员在公路上步行或开车,通过肉眼定时定量进行检查,发现路面病害后使用相关工具判断病害严重程度,这种方法效率低,需要耗费大量的人力和物力。随着深度学习相关技术的发展^[1],人工检测已逐渐被基于目标检测的检测方法所取代。Xie 等^[2]

提出一种改进 YOLOv3 算法对路面病害进行检测,提出共享卷积注意力模块(shared convolutional block attention module, SCBAM),极大提高病害识别精度。Wu 等^[3]研究了路面病害数据集的预处理方法,并利用 YOLOv5 模型对路面病害进行检测。Yan 等^[4]提出一种 SSD(single shot multi-box detector),通过添加可变形卷积,实现复杂环境下高精度实时检测。这些研究促进路面病害检测技术的进一步发展,但路面病害尺度差异大,背景干扰多,病害特征不明显等导致病害检测精度差的问题目前依旧存在。

为了提高路面病害检测效率,本文基于 YOLOX-s 算法进行改进创新,设计 CSP_Ghost 模块以替换原始网络中的 CSPLayer 模块,该设计模块将 CSP(cross stage parital)结构同 G-bneckv2 模块相结合,在降低通用卷积层的计算成本、减少网络参数数量的同时提高网络的特征提取能力;在颈部网络中引入高效通道注意力(efficient channel attention, ECA)模块,以少数参数数量的增加,降低干扰因素的影响,加强模型的特征融合效果,提高网络对不同大小特征图的识别精度;设计 DSPPF 空间金字塔结构,将混合空洞卷积金字塔结构同 SPPF(spatial pyramid pooling-fast)结构进行创新结合,解决空间金字塔池化(SPP)结构不足之处,扩大感受野,有助于提取特征稀疏信息。

1 YOLOX 算法

YOLOX 算法是一阶段的目标检测算法,具有

YOLOX-s、YOLOX-m、YOLOX-l、YOLOX-x 四种网络模型结构^[5]。YOLOX-x 具有最高精度和最大参数量,YOLOX-m 和 YOLOX-l 在精度和计算效率之间取得了良好的平衡,而 YOLOX-s 是最轻量级的版本。YOLOX 网络以 YOLOv3-SPP 算法为基准模型,引入解耦头、数据增强、无锚点以及标签分类等^[6]优秀创新技术,在识别精度和推理速度方面取得了显著进步。YOLOX 网络主要由输入端、主干网络、颈部网络以及检测头 4 部分组成。其中:输入端对图像进行数据增强^[7-8],以增强网络的鲁棒性;主干网络负责提取路面病害特征,通过卷积操作捕捉目标信息;颈部网络对提取到的特征进行多尺度融合,以适应不同尺度的目标检测任务;检测头输出检测结果,包括目标的位置和类别信息。YOLOX 网络结构图如图 1 所示。考虑路面病害检测需求以及实际设备情况,选择网络深度较小的 YOLOX-s 作为基准模型。

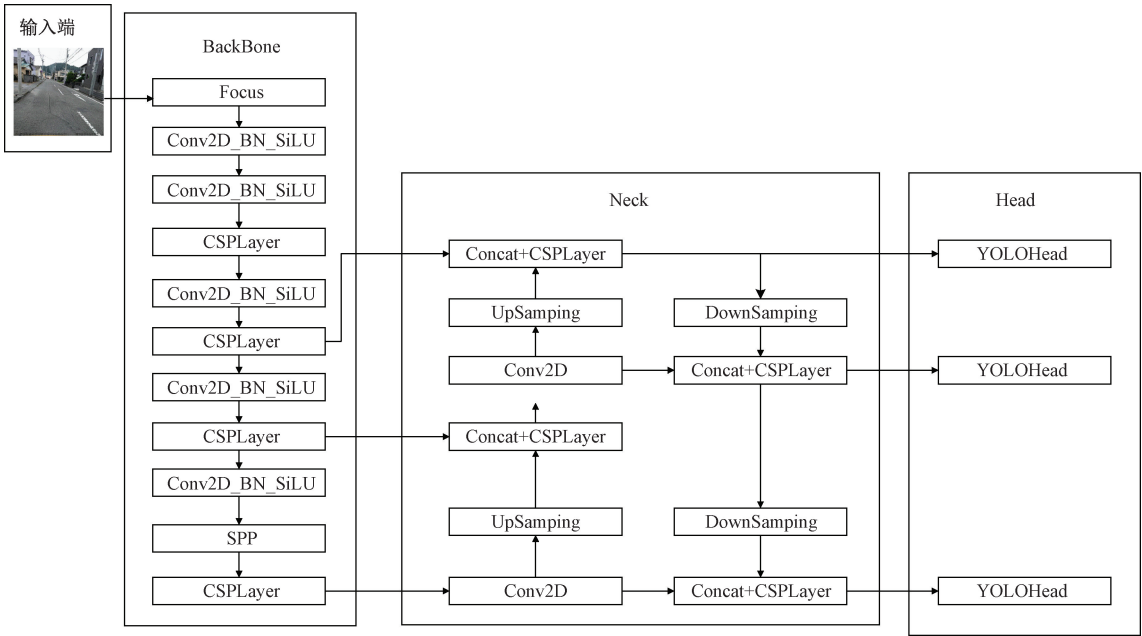


图 1 YOLOX 网络结构
Fig. 1 YOLOX network structure

2 改进的 YOLOX 算法

2.1 CSP_Ghost 模块

由于路面病害图像中背景复杂,干扰物品较多,为了强化某种病害特征,需要输入大量同类型病害图像,产生大量特征图。然而这些相似的特征图存在冗余映射现象,会消耗大量的计算资源。为了减少冗余带来的负面影响,使用 Ghost 模块^[9]通过简单的线性操作生成特征图。如图 2 所示,在 Ghost 模块中,输入图像先经过常规卷积操作压缩通道数,然后采用逐层卷积获得更多特征图,最后将前两步生成的特征图进行整合,生成最终的输出特征图。




图 2 Ghost 模块
Fig. 2 Ghost module

Ghost 模块可以提高网络计算速度,却只能建模一个窗口内的局部特征信息,降低了对特征的表征能力。解耦全连接(decoupled fully connected, DFC)注意力模块^[10-11]能捕

获长距离空间信息以增强表征能力,有效解决了原始 GhostNetv1 感受野小的问题,如图 3 所示。DFC 模块可以通过具有固定权重的全连接层(FC)生成具有全局感受野的注意力图,为了有效降低注意力模块计算复杂度,将其沿着水平、垂直两个方向聚集特征,将计算复杂度可以降低到 $O(H^2W + HW^2)$,其产生注意力图公式如式(1)、(2)所示。

$$a'_{hw} = \sum_{h'=1}^H F^H_{h,h'w} \odot z_{h'w}, h = 1, 2, \dots, H; w = 1, 2, \dots, W \tag{1}$$

$$a_{hw} = \sum_{w'=1}^W F^W_{w,hw'} \odot a'_{hw'}, h = 1, 2, \dots, H; w = 1, 2, \dots, W \tag{2}$$

式中: F^H 、 F^W 是变换权值。




图 3 DFC 注意力机制

Fig. 3 DFC attention mechanism

如图 4(a)所示,两个 Ghost 模块结合生成 G-bneckv1 模块,第 1 个 Ghost 模块作为扩展层,增加了通道数。第 2 个 Ghost 模块减少通道数,将通道数降低到与输入通道数一致以与 shortcut 路径匹配。G-bneckv2 模块如图 4(b)所示,结构将 DFC 注意力机制与第一个 Ghost 模块并行相乘,以增强扩展的特征,第 2 个 Ghost 模块减少通道数。

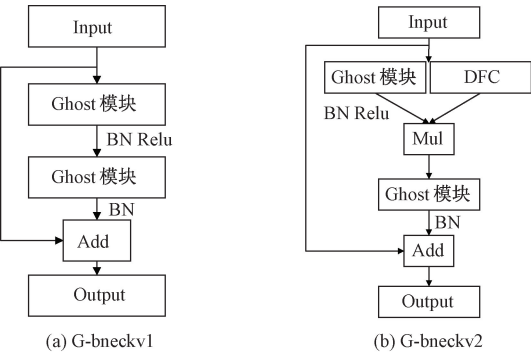


图 4 G-bneckv1/v2 结构

Fig. 4 G-bneckv1/v2 structure

如图 5 所示,将 CSP 结构同 G-bneckv1/v2 结构结合得到 CSP_Ghost 模块,该模块使用 G-bneckv1/v2 模块替换普通卷积,加深网络深度,提高主干网络特征提取能力,

同时降低网络参数。

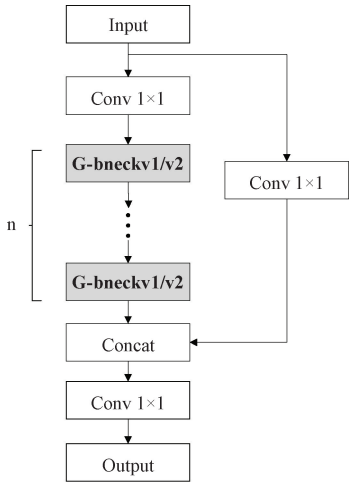


图 5 CSP_Ghostv1/v2 结构

Fig. 5 CSP_Ghostv1/v2 structure

为了验证 CSP_Ghostv1/v2 模块对 YOLOX 网络的影响,本文分别使用 G-bneckv1/v2 替换 Bottleneck 操作,并在路面病害数据集上进行 300 epoch 训练,训练结果如表 1 所示。

表 1 不同 CSP_Ghost 结构加入 YOLOX 的检测效果
Table 1 The detection effect of different CSP_Ghost structures added to YOLOX

网络模型	mAP@0.5/ %	Weight size/MB	Params/ MB
YOLOX-s	59.24	34.35	8.97
+CSP_Ghostv1	60.05	28.40	7.39
+CSP_Ghostv2	61.59	31.47	8.14

换 CSPLayer 模块后,算法的平均精度均值 (mean average precision, mAP) 提高了 0.81%,权重大小减少了 5.95 MB,参数量减少了 1.58 MB。而使用 CSP_Ghostv2 替换 CSPLayer 模块后,算法的 mAP 提高了 2.35%,权重大小减少了 2.88 MB,参数量减少了 0.83 MB。两者相比可知,使用 CSP_Ghostv2 的 mAP 提升更为显著,且两者在参数量上的差距并不明显。因此,选择 G-bneckv2 模块替换 CSPLayer 结构中的 Bottleneck 层,构建最终的 CSP_Ghost 模块,用以设计 YOLOX-G 网络模型实现对路面病害的检测。

2.2 改进的 DSPPF 结构

在路面病害检测中,路面病害位置大小不定,其中,纵横裂缝特征细长,坑洞病害形状各异,各类病害特征大小、形状差异明显,训练时很难保证大目标与小目标同时被识别出来,严重影响网络定位的准确性。SPP 空间金字塔池化结构能实现局部特征和全局特征的特征图融合,但其参数量多,融合效果差。SPPF 结构在对 SPP 进行了改进,不

影响效果的前提下降低了网络参数量,但依旧无法有效提取多尺度上下文信息^[12]。

为了增强网络的多尺度检测效果,提高网络提取识别不同路面病害特征的性能,本文提出 DSPPF 混合空洞空间金字塔池化结构,将 SPPF 中的 MaxPool 层替换为不同膨胀系数的空洞卷积,空洞卷积可以避免信息的大量丢失,同时增大感受野,使得模型的性能有所提升^[13]。使用不同膨胀系数 $[1,2,5]$ 的空洞卷积^[14],能全面覆盖整个区域,提高模型对小尺度特征的识别精度,使模型更具鲁




图 6 DSPPF 模块
Fig. 6 DSPPF module

2.3 注意力机制的引入

为了提高路面病害检测精度,使网络更关注路面病害重要信息,忽略不必要的信息,本文引入 ECA 通道注意力模块,该模块可以降低背景信息通道权重,减少干扰因素的负面影响,同时增加网络对通道间关系的处理能力,以提升网络性能^[15-16]。

ECA 注意力模块提出了一种局域跨信道交互策略和自适应一维卷积的方法,通过这种方法,可以在不降低维度的情况下提高注意力信息的准确性。因此,引入 ECA 模块,能有

棒性。
DSPPF 模块整体结构如图 6 所示,输入特征先经过一个 1×1 卷积压缩通道信息,再依次经过不同膨胀系数的空洞卷积,最后将 4 条不同通道的通道信息进行合并。在第一个通道直接输出 1×1 卷积压缩后的特征图,另外 3 条通道分别经过 $[1]$ 、 $[1,2]$ 、 $[1,2,5]$ 不同数量、不同膨胀率的空洞卷积提取不同感受野的特征图,这样有助于提取特征稀疏信息,提高特征的多样性。此外,每次卷积后会进行批量归一化和 Silu 激活函数。

效提高网络特征提取能力而不增加网络参数量、计算量,其结构如图 7 所示,其中 H 、 W 、 C 分别是特征图的高、宽、通道数, GAP(global average pooling)表示全局平均池化, k 表示局部跨通道交互的覆盖率。 K 可以通过通道维度 C 的映射自适应地确定,卷积核大小 k 计算公式如式(3)、(4)所示。

$$C = \phi(k) = 2^{(\gamma * k - b)} \tag{3}$$

$$k = \phi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \tag{4}$$

式中: $\lfloor A \rfloor_{\text{odd}}$ 表示距离 A 最近的奇数, $b=1$, $\gamma=2$ 。




图 7 ECA 注意力机制
Fig. 7 ECA attention mechanism

2.4 改进的 YOLOX-GED 网络结构

使用 CSP_Ghost 替代 YOLOX-s 网络中 CSPLayer 层,使用 DSPPF 结构替换主干网络中 SPP 结构,并在 PANet 结构中添加 ECA 注意力机制,改进后的 YOLOX-GED 网络结构如图 8 所示。

3 实验结果与分析

3.1 RDD2020 数据集介绍

本文使用数据集为开源的 RDD2020 数据集^[17],该数据集包含从印度、日本和捷克共和国收集的 21 041 张道路

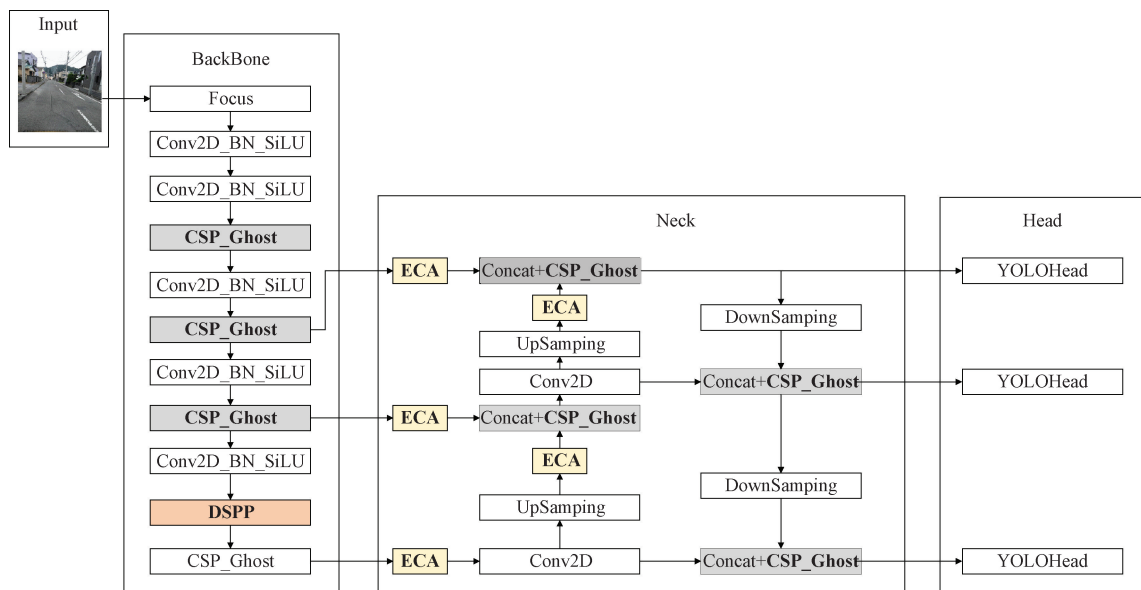


图8 YOLOX-GED网络结构

Fig. 8 YOLOX-GED network structure

图像,其中包括 31 000 多起道路损坏实例。数据集中共有 9 类: ['D00', 'D01', 'D10', 'D11', 'D20', 'D40', 'D43', 'D44', 'D50'], 其中 D00 是纵向裂缝; D01 是纵向拼接缝; D10 是横向裂缝; D11 是横向拼接缝; D20 是龟裂; D40 是坑洞; D43 是十字路口模糊; D44 是白线模糊; D50 是井盖。

考虑到实际路面养护情况以及数据集各类别样本不平衡,纵向拼接缝 D01 与横向拼接缝 D11 两个类型的样本数据集太少,故本文主要选择纵向裂缝 D00、横向裂缝 D10、龟裂 D20、坑洞 D40、十字路口模糊 D43、白线模糊 D44、井盖 D50 七类病害特征用于深度学习模型训练。训练前使用随机划分的方法,将数据集按 8:2 的比例划分为训练集与验证集,划分后,训练集有 16 833 张图片,验证集有 4 208 张图片。数据集各类别分布如图 9 所示。




图9 数据集类别分布图

Fig. 9 Dataset category distribution map

3.2 实验环境

本实验是基于 CPU 为 Intel Core i5-10400 CPU, GPU 为 NVIDIA GeForce RTX 2080 11 G 的计算机完成的, Python 版本为 3.9, 采用 PyTorch 框架。由于设备硬件因素限制, 本文使用 YOLOX-s 网络模型进行训练验证, 训练过程中所有网络均不使用预训练模型, 输入特征图大小为 640×640 , 批量大小设置为 4, 训练迭代次数为 300 轮。

3.3 评价标准

本文使用精确度 Pr、召回率 Re、平衡 F 分数 F1 和平均精度均值 mAP 作为网络的性能标准, 其中准确度 Pr 反应了网络预测的准确性, 当 Pr 越大时, 预测出的正例纯度越高, 计算公式如式(5)所示。

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

式中: TP 是预测为正例, 真实值为正例的个数; FP 是预测为正例, 实际为负例的个数。

召回率反应路面病害正确检测到的数量占总正样本的比例, 公式如式(6)所示。

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

式中: FN 是预测为负例, 实际是正例的个数。

平均精度均值 mAP 指的是各类别平均精度 (average precision, AP) 的平均值, mAP0.5 指的是 IOU 阈值为 0.5 时多个类别 AP 值的平均值, 能衡量网络的检测精度, 计算公式如式(7)所示。

$$mAP = \frac{1}{m} \sum AP(i) \quad (7)$$

平衡 F 分数 F1 通过将 precision 和 recall 两个模型评价指标做调和平均, 得到一个综合的评价模型好坏的指

标,计算公式如式(8)所示。

$$F1 = \frac{2 \times Pr \times Re}{Pr + Re}$$

(8)

3.4 注意力机制选择实验

在路面病害检测中,为了评价 ECA 注意力机制对 YOLOX-G 网络的提升效果,分别将 ECA 与压缩和激励(squeeze-and-excitation, SE)注意力模块、协调注意力(Coordinate attention, CA)模块加入 YOLOX-G 网络结构中进行对比实验,实验结果如表 2 所示。

表 2 加入不同注意力机制的检测结果
Table 2 Incorporate the detection results of different attention mechanism

网络模型	mAP@0.5/%	Params/MB
YOLOX-G	61.59	8.14
+SE	61.73	8.18
+CA	62.04	8.25
+ECA	62.56	8.15

如表 2 所示,与 YOLOX-G 相比,引入 SE 模块后网络的 mAP 提高了 0.14%,参数量增加了 0.04 MB;引入 CA 模块后网络的 mAP 提高了 0.45%,参数量增加了 0.11 MB;而引入 ECA 模块后网络的 mAP 提高了 0.97%,参数量仅增加 0.01 MB。结果表明,与引入 SE、CA 注意力模块相比,引入 ECA 注意力模块的 mAP 提升效果最为明显,且其增加的参数量最少,更有利于对不同尺度路面病害的准确检测。

3.5 消融实验

为了验证本文提出的各优化策略的有效性,使用 YOLOX-s 模型为基准模型,控制变量的情况下,进行多组消融实验。以 YOLOX-s 为基础的,将主干网络中 CSPlayer 换为本文设计的 CSP_Ghost 模块得到 YOLOX-G 网络。将 ECA 注意力机制嵌入 YOLOX-G 网络中,得到 YOLOX-GE。将 SPP 空间金字塔池化结构替换 DSPPF 混合空洞空间金字塔模块,得到 YOLOX-GED。消融实验结果如表 3 所示。

表 3 消融实验结果
Table 3 Ablation test results

网络模型	R/ %	F1/ %	mAP@0.5/ %	Params/ MB
YOLOX-s	55.01	59.08	59.24	8.97
YOLOX-G	58.53	62.00	61.59	8.14
YOLOX-GE	57.80	62.39	62.56	8.15
YOLOX-GED	59.47	63.71	64.56	8.26

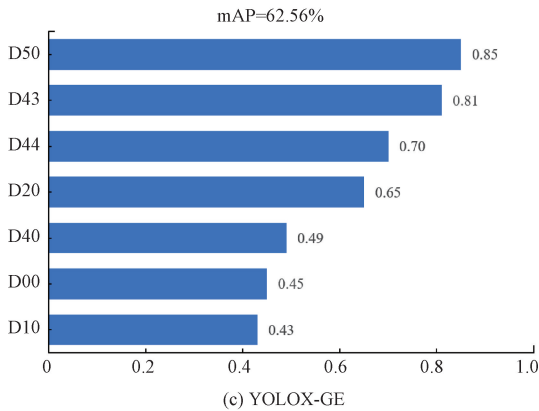


YOLOX-G 与 YOLOX-s 对比可知,CSP_Ghost 模块能有效降低网络参数,加深网络结构,提高网络对病害特

征的提取能力,其召回率、平衡 F 分数、平均精度分别提高了 3.52%、2.92%、2.35%,参数量减少了 9.3%。YOLOX-GE 网络与 YOLOX-G 对比可知,ECA 注意力机制去除特征中的噪音信息,使其精确度、平均精度得到提升。YOLOX-GED 与 YOLOX-GE 对比可知,DSPPF 混合空洞金字塔池化能有效解决路面病害尺度差异大的情况,其召回率、平衡 F 分数、平均精度分别提升了 1.67%、1.32%、2.0%。最终,相较于 YOLOX-s 网络,YOLOX-GED 网络的 mAP 提升了 5.32%。

消融实验中,不同病害类型识别精度如图 10 所示。

3.6 对比试验

为了进一步评价 YOLOX-GED 网络模型性能,本文使用不同模型在同一训练集、验证集、设备上进行对比实验。实验结果如表 4 所示。






图 10 消融实验 mAP 对比图

Fig. 10 Comparison of ablation experiments with mAP

表 4 不同算法对比实验结果

Table 4 Experimental results are compared with different algorithms

网络模型	R/ %	F1/ %	mAP@0.5/ %	Params/ MB
YOLOX-s	55.01	59.08	59.24	8.97
YOLOv5s	52.43	54.00	51.19	7.07
Ghost-YOLOv5s	52.51	53.04	49.57	5.70
Faster RCNN	59.30	60.18	60.26	136.80
YOLOv7	62.65	61.27	60.99	37.62
YOLOX-GED	59.47	63.71	64.56	8.26

由表 4 可知,与其他算法结果相比,本文改进后的算法 YOLOX-GED 在路面病害检测有最好的性能,mAP 相比于其他网络,领先了至少 3.57%,同时参数量仅多余 YOLOv5s、Ghost-YOLOv5s。

为了更加直观的体现出改进的 YOLOX-GED 算法的性能,随机选择 4 张包含不同病害信息的路面病害图像进行可视化实验,观察 YOLOX-s 算法与 YOLOX-GED 算法对不同病害的检测效果,检测结果如图 11 所示,其中,左边是原始的 YOLOX-s 算法的检测结果,右边是改进后的 YOLOX-GED 算法的检测结果。

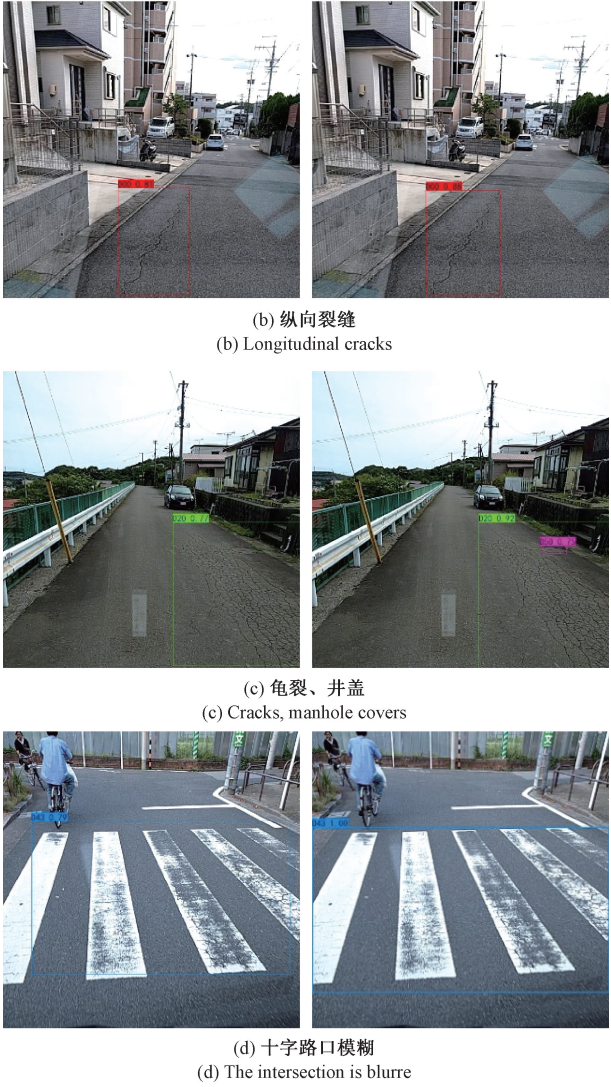
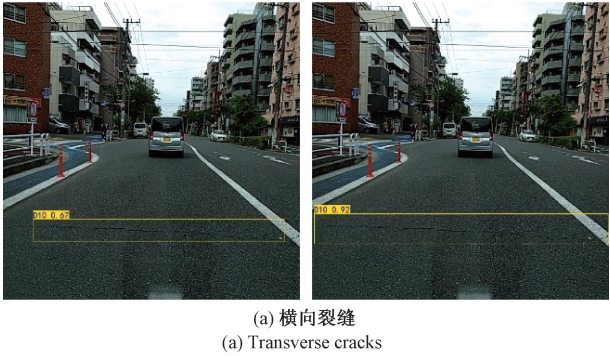


图 11 不同算法检测结果图

Fig. 11 Diagram of the detection results of different algorithms

如图 11 所示,根据 YOLOX-s 算法与 YOLOX-GED 算法的检测结果可知,在检测横向裂缝、纵向裂缝和十字路口模糊时,YOLOX-s 算法定位病害目标时存在定位误差,未能准确覆盖全部病害区域,而 YOLOX-GED 算法不仅能精确定位病害目标,而且其对各类病害的检测置信度分数都有所提高,例如检测横向裂缝时置信度分数由 67% 提升到了 92%,检测纵向裂缝时置信度分数由 81% 提升到了 88%。在检测龟裂和井盖病害时,YOLOX-s 算法存在漏检的情况,未能检测出井盖,而 YOLOX-GED 算法能检测出所有病害,且置信度得分更高。

4 结 论

对于路面病害检测过程中,存在的背景复杂、病害尺度差异大、病害信息不明显等问题,本文以 YOLOX-s 网络框架为基础,将 Ghost 模块与 DFC 注意力模块构建的 G-

bneckv2 模块与 YOLOX 主干网络中的 CSP 模块相结合,生成 CSP_Ghost 模块,降低网络参数,提高网络识别速度,并加深特征提取网络深度,更有效的提取病害特征;提出 DSPPF 混合空洞空间金字塔结构,有效提高网络多尺度性能,扩大网络感受野;引入 ECA 注意力机制减少特征中的噪音信息。实验结果表明本文改进十分有效,在路面病害识别精确度、F1 分数、平均精度等方面与其他网络相比有着明显优势。

参考文献

- [1] 翟军治,孙朝云,裴莉莉,等.多尺度特征增强的路面裂缝检测方法[J]. 交通运输工程学报,2023,23(1): 291-308.
ZHAI J ZH, SUN ZH Y, PEI L L, et al. Pavement crack detection method based on multi-scale feature enhancement [J]. Journal of Traffic and Transportation Engineering, 2023, 23(1): 291-308.
- [2] XIE AN D, YU ZH, CAO X CH, et al. Efficient pavement distress detection based on attention fusion and feature integration [C]. 2022 Prognostics and Health Management Conference(PHM-2022 London), 2022:374-377.
- [3] WU ZH Y, ZHANG Y, ZHANG ZH Y, et al. A pavement distress detection method based on YOLOv5 model[C]. 2022 41st Chinese Control Conference(CCC), 2022: 39-44.
- [4] YAN K, ZHANG ZH H. Automated asphalt highway pavement crack detection based on deformable single shot multi-box detector under a complex environment[J]. IEEE Access, 2021, 9: 150925-150938.
- [5] 胡皓,郭放,刘钊.改进 YOLOX-S 模型的施工场景目标检测[J]. 计算机科学与探索,2023,17(5): 1089-1101.
HU H, GUO F, LIU ZH. Object detection based on improved YOLOX-S model in construction sites[J]. Journal of Frontiers of Computer Science and Technology, 2023, 17(5): 1089-1101.
- [6] GE ZH, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. ArXiv preprint arXiv:2107. 08430, 2021.
- [7] 王阳萍,韩淑梅,杨景玉,等.改进 YOLOv4 的铁路沿线遥感影像地物检测方法[J]. 光谱学与光谱分析, 2022,42(10):3275-3282.
WANG Y P, HAN SH M, YANG J Y, et al. Improved YOLOv4 remote sensing image detection method of ground objects along railway[J]. Journal of Spectroscopy and Spectral Analysis, 2022, 42(10): 3275-3282.
- [8] 凌强,刘宇,王春举,等.DN-YOLOv5 的金属双极板表面缺陷检测算法[J]. 哈尔滨工业大学学报,2023, 55(12):104-112.
LING Q, LIU Y, WANG CH J, et al. DN-YOLOv5 algorithm for detecting surface defects of metal bipolar plates[J]. Journal of Harbin Institute of Technology, 2023, 55(12): 104-112.
- [9] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations [C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 1577-1586.
- [10] TANG Y H, HAN K, GUO J Y, et al. GhostNetV2: Enhance cheap operation with long-range attention[J]. Advances in Neural Information Processing Systems, 2022, 35: 9969-9982.
- [11] 王迎龙,孙备,丁冰,等. BG-YOLO:复杂大视场下低慢小无人机目标检测方法[J]. 仪器仪表学报,2025, 46(2):255-266.
WANG Y L, SUN B, DING B, et al. BG-YOLO: A low-altitude slow-moving small UAV targets detection method in complex large field of view[J]. Chinese Journal of Scientific Instrument. 2025, 46 (2): 255-266.
- [12] 张朝阳,张上,王恒涛,等.多尺度下遥感小目标多头注意力检测[J]. 计算机工程与应用,2023, 59(8): 227-238.
ZHANG ZH Y, ZHANG SH, WANG H T, et al. Multi-head attention detection of small targets in remote sensing at multiple scales [J]. Computer Engineering and Applications, 2023, 59(8): 227-238.
- [13] 候少麒,梁杰,殷康宁,等.基于空洞卷积金字塔的目标检测算法[J]. 电子科技大学学报,2021, 50(6): 843-851.
HOU SH Q, LIANG J, YIN K N, et al. Object detection algorithm based on atrous convolutional pyramid [J]. Journal of University of Electronic Science and Technology of China, 2021, 50 (6): 843-851.
- [14] 袁帅,王康,单义,等.基于多分支并行空洞卷积的多尺度目标检测算法[J]. 计算机辅助设计与图形学学报, 2021,33(6):864-872.
YUAN SH, WANG K, SHAN Y, et al. Multi-scale object detection method based on multi-branch parallel dilated convolution [J]. Journal of Computer-Aided Design & Computer Graphics, 2021, 33(6): 864-872.
- [15] 郝巨鸣,杨景玉,韩淑梅,等.引入 Ghost 模块和 ECA 的 YOLOv4 公路路面裂缝检测方法[J]. 计算机应用, 2023,43(4):1284-1290.
HAO J M, YANG J Y, HAN SH M, et al. YOLOv4

highway pavement crack detection method using Ghost module and ECA [J]. Journal of Computer Applications, 2023, 43(4): 1284-1290.

[16] 赵佰亭,张晨,贾晓芬. ECC-YOLO: 一种改进的钢材表面缺陷检测方法[J]. 电子测量与仪器学报, 2024, 38(4):108-116.

ZHAO B T, ZHANG CH, JIA X F. ECC-YOLO: An improved method for detecting surface defects in steel [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 108-116.

[17] DEEKSHA A, HIROYA M, KUMAR S G, et al. RDD2020: An annotated image dataset for automatic road damage detection using deep learning[J]. Data in Brief, 2021, 36:107133.

作者简介

封淑玲(通信作者), 硕士, 副教授, 主要研究方向为深度学习算法、计算机视觉与人工智能。
E-mail:709732923@qq.com

王琪, 硕士研究生, 主要研究方向为深度学习算法、目标检测。
E-mail:1961252365@qq.com

吕成伊, 硕士研究生, 主要研究方向为深度学习算法、目标检测。
E-mail:1718753052@qq.com