

基于改进 simAM-YOLOv8 的路面 多病害识别方法

单 飞^{1,2}, 李 辉¹, 孙 浩², 聂世刚², 申忠虎²

(1. 同济大学道路与交通工程教育部重点实验室, 上海 201804; 2. 河南交通发展研究院有限公司, 郑州 450066)

摘 要: 针对道路路面病害数据多模态和识别准确率低的问题, 提出了一种基于无参数注意力机制 simAM 改进 YOLOv8 的路面多病害识别算法。利用自有路面病害数据集, 在 YOLOv8 结构中嵌入 Res2Net, 在计算负载量相似的基础上增强多规模特征提取能力; 采用 simAM 模块进一步调整不同尺度特征图的权重, 实现对目标的检测改善; 利用遗传算法提升模型自动寻参速度, 使用 HSV 以及 Mosaic 等图像增强手段扩充小样本病害。实验结果表明: 改进后的 simAM-YOLOv8 算法对沥青、水泥等不同类型路面的裂缝、破碎板、修补等病害识别结果相较原网络精确率整体提升了 15.3%, 召回率整体提升了 13.1%, 表现出了较好的智能识别效果, 可在公路路况自动化检测方面发挥重要作用。

关键词: 智能交通; 路面病害; 识别算法; simAM; YOLOv8; Res2Net

中图分类号: TP391.4; U495 **文献标志码:** A **文章编号:** 1671-5497(2026)01-0219-12

DOI: 10.13229/j.cnki.jdxbgxb.20240586

Pavement distress identification method based on improved simAM-YOLOv8

SHAN Fei^{1,2}, LI Hui¹, SUN Hao², NIE Shi-gang², SHEN Zhong-hu²

(1. Key Laboratory of Road and Traffic Engineering, Ministry of Education, Tongji University, Shanghai 201804, China; 2. Henan Transportation Development Research Institute Co., Ltd., Zhengzhou 450066, China)

Abstract: To solve the problems of multi-modal data and low recognition accuracy in road pavement distress detection, an improved pavement multi-distress recognition algorithm based on the YOLOv8 model enhanced with the non-parametric attention mechanism simAM is proposed. Utilizing the self-owned pavement distress dataset, Res2Net is embedded into the YOLOv8 structure to enhance multi-scale feature extraction capabilities while maintaining similar computational loads. The simAM module is employed to further adjust the weights of feature maps at different scales, improving the detection of targets. Genetic algorithm is used to increase the speed of automatic parameter searching for the model, and

收稿日期: 2024-05-26.

基金项目: 交通运输行业重点科技项目(2022-MS1-019); 河南省交通运输科技计划项目(2022-5-6, 2023-4-2).

作者简介: 单飞(1983-), 男, 博士研究生, 正高级工程师. 研究方向: 智能交通, 交通大数据, 交通规划与管理.

E-mail: shanfei@tongji.edu.cn

通信作者: 李辉(1983-), 男, 教授, 博士. 研究方向: 智能交通, 交通大数据, 交通规划与管理. E-mail: hli@tongji.edu.cn

image enhancement techniques such as HSV and Mosaic are employed to expand the small sample distresss. Experimental results show that the improved simAM-YOLOv8 algorithm significantly improves accuracy and recall rates for various pavement distresss such as cracks, broken panels, repairs, etc., on asphalt, cement, and other road surfaces. Specifically, the precision rate has increased by 15.3% and the recall rate has increased by 13.1% compared to the original network, demonstrating excellent intelligent recognition performance, and playing an important role in automated detection of highway conditions.

Key words: intelligent transportation; pavement distress; recognition algorithm; simAM; YOLOv8; Res2Net

0 引言

近年来,国内公路设施随着基建快速增长,至 2023 年底总里程已达 544 万 km。地域广阔、地形多样导致路网建设与病害特征各异,信息采集与病害检测面临挑战。大数据、机器学习等技术可有效应用于公路病害检测与管理,降低成本,提升效率^[1-3]。

路面病害检测技术最早于 20 世纪 80 年代在欧美国家开始运用^[1],该技术在国外最具代表性的系统有美国 Earth 公司研发的 PCES 系统、英国 HARRIS 系统^[4]、加拿大辉固-路德威(Fugro Roadware)等^[5]。目前我国最早的路面检测系统是由南京理工大学研发的^[6],该系统利用目标检测算法在限时时速下可对部分病害进行检测,后期类似的病害检测算法逐渐在国内市场陆续出现。但是随着路面病害种类不断增加,病害检测算法针对小目标检测的弱项也逐渐显现出来,导致最后还是需要投入大量人工进行复核检测。

目前,主流检测方法有单目视觉、三维重建和振动检测。单目视觉因其低成本、广范围、高精度及高灵活性成了研究热点,主要分为传统图像处理和深度学习两类^[6]。传统图像算法如 OpenCV 难适应多变道路,效果有限。深度学习尤其是 ViT 模型,融合 Transformer 理念,通过分层交叉注意力与多尺度特征融合,提升计算效率,成为新趋势^[7]。

本文针对不同类型的道路以及不同等级的道路分别进行定制化深度学习模型训练开发,实现了面向不同路况进行更加精准的病害目标检测定位^[8,9],主要利用图像算法中的 YOLOv8 作为初始化训练模型^[10],基于原始 YOLOv8 框架基础进行改进优化,改进点分别有:①算法结构增加 simAM^[10-12]模块,可以使网络关注到重要特征,抑制不重要特征,提升检测精度和鲁棒性;②在网络

架构中融入 Res2Net,显著增强了多尺度特征提取的能力,同时保持了与原架构相当的计算负载;③算法结构中加入遗传算法,有效提高了模型自动寻参速度,确保使用最优参数进行训练,优化模型性能;④通过图像增强技术,不仅丰富了样本的多样性,还显著提高了模型在高速运动场景中识别病害的准确性,增强了模型的泛化能力。

1 目标检测算法

1.1 YOLOv8 算法原理

计算原理:YOLOv8 首先会将一幅图像分成 3 类不同规格的特征尺度,head 模块进行类别预测分支和回归预测分支,分类预测分支进行 Sigmoid 计算,回归预测分支进行解码还原成 xyxy 格式,通过预测的 confidence 值进行阈值过滤比较,将剩下的检测框还原到原图尺寸上,完成最后的计算。

1.2 YOLOv8 网络架构

以 YOLO 系列为代表的单阶段目标检测算法具有检测速度快等优点,多用于实时性应用场景。本文以 YOLOv8 网络结构为基础,结合 simAM 注意力机制等算法改善结构,提高目标检测的准确率。

YOLOv8 的网络结构分为 3 部分:backbone 骨干网络、neck 颈部结构、head 头部结构^[13-15],如图 1 所示。本文在具体处理过程中利用 YOLOv8s. yaml 文件,将 head 与 neck 放在一起,最终能够达到 YOLOv8 的网络结构为全卷积网络,即网络结构主要由卷积层、批归一化层等构成,不包含全连接层。

neck 结构是一个特征金字塔,主要作用就是把浅层图形特征和深层语义特征相结合,最终获取更完整的特征。

可以看出,neck 在左路通过 upsample 上采样




图 1 YOLOv8网络结构图

Fig. 1 YOLOv8 network structure

的方式,向特征图中插值,使特征图的尺度变大,以便融合来自 backbone 的特征图,做特征的向上融合,特征图不断变大;neck 的右路继续做下采样,一是为了获取不同尺度的特征图,二是使浅层的图形特征与深层的语义特征做更好的融合,而不仅仅是简单的 Concat。

head 层就是 Detect 模块,如图 2 所示, Detect 模块的网络结构是由一组卷积和全连接层组成,不同层级应用了不同的检测器,每一个检测器预测一个尺度的边界框。

图 2 中右边的 3 张特征图其实就是 3 个 $W \times H$ 网格。第 1 个网格为 80×80 ,第 2 个网格为 40×40 ,第 3 个网格为 20×20 ,进入 CBL 池化层进行两次下采样,box 回归分支保证回归器拥有捕捉目标位置和尺度能力,其中 $C_{reg} = \max(16, c1/4, 4 \times reg_max)$ 表示每个锚点输出的通道数,默认为 16, $c1/4$ 表示特征图通道数的四分之一,为了实现回归器通道数不超过特征图通道数四分之一,避免通道数过多导致模型复杂和计算量大, $4 \times reg_max$ 表示目标位置和尺寸的参数中最大




图 2 head 网络原始结构图

Fig. 2 Original structure diagram of head network

值乘以 4, 得到一个与目标尺寸相关的参数值, 保证有足够通道数来使用目标的不同尺度, 预防信息丢失和误差偏大。cls 类别分支中的 cl 为特征图的通道数, cls_num 为目标分类的个数, 在本文中根据病害选择该值为 6。结合实验的数据质量, 本文优化调整置信度值由 0.25 调整为 0.2, 调整的原因是原始数据量不够多以及图片质量差产生的漏检。

2 改进 YOLOv8 模型

2.1 网络结构改进

Backbone 骨干网络主要实现提取特征和缩小特征图, 主要结构有 Conv 模块、C2f 模块、SPPF 模块^[13]。Conv 模块主要起到提取特征的作用, 是由一个 Conv2d、一个 batchNorm2d 和激活函数构成。

C2f 模块的主要作用也是提取特征, 主要由两个 Conv 模块和两个 BottleNeck 模块构成^[16], 本文对 C2f 模块中的 BottleNeck 模块进行改进优化, 主要添加了 CNN 新模块 Res2Net。

图 3 中, 左侧为 CNN 网络架构的基本构成, 右侧为本文采用的 Res2Net 模块^[17]。Res2Net 这一新模块的内部连接方式借鉴了残差网络(ResNet)的设计理念。它采用单个较小的 3×3 过滤器替代了原本的过滤器组, 并通过层级残差式的连接方式将不同的过滤器组进行组合。这种设计使得 Res2Net 在特征提取方面展现出更强大的多尺度能力, 而计算量却与原始架构保持相近水平。




图 3 添加 Res2Net 前后模块图

Fig. 3 Module diagram with and without Res2Net

Res2Net 模块的多尺度表示能力也和 CNN 的分层特征聚合模型彼此独立, 因此可以很容易地将 Res2Net 模块集成到现有的其他优秀 CNN 模型中, 例如 ResNet、ResNeXt 和 DLA 等^[17]。Res2Net 以其简洁的结构和卓越的性能, 展示了

CNN 在更精细粒度的多尺度表示能力方面的巨大潜力。除了现有的深度、宽度和基数维度外, Res2Net 还引入了一个新的重要维度——“尺度”(Scale), 证明了其在提升网络性能方面的不可或缺和有效性。

2.2 算法模型改进

在 SPPF 模块中, 本文引入了注意力机制 simAM, 用于调整不同尺度特征图的权重。通过这一机制, 网络能够更专注于关键特征, 降低对次要特征的关注, 从而增强对小目标的检测能力。这不仅提高了检测的精度, 还增强了网络对噪声和干扰的鲁棒性, 确保检测结果更可靠。总体而言, simAM 的应用有效提升了检测的性能和稳定性。本文采用目标检测算法框架中最新的 YOLOv8 作为底层框架, 其中, 注意力机制目前的主流有 Transformer、simAM 等, 用于算法改进时, Transformer 存在以下劣势: ①训练数据量要求高, 无法满足小样本模型拟合; ②内存消耗大, 无法满足路检设备轻量化要求; ③内核原理较复杂, 无法满足后期定制化改造; ④其全局注意力计算应对高分辨率图输入时计算量巨大, 无法满足实时性要求。因此, 结合实际道路病害检测软硬件要求本文未采用 Transformer。

本文使用到的是 simAM 注意力机制, simAM 的实现方式是对输入特征图 χ 进行标准化, 并计算出每个像素点与其他像素点的相似度。具体来说, 对于输入特征图 $\chi \in \mathbb{R}^{B \times C \times W \times H}$, 其中 B 表示 batch size, C 表示通道数, H 和 W 分别表示特征图的高度和宽度。simAM 计算过程如下: 计算特征图 χ 的均值 $\mu \in \mathbb{R}^{B \times C \times 1 \times 1}$ 和方差 $\text{var} \in \mathbb{R}^{B \times C \times 1 \times 1}$, 其中均值和方差分别在 H 和 W 的维度上计算。对特征图 B 进行标准化, 得到标准化的特征图 $\tilde{\chi} \in \mathbb{R}^{B \times C \times 1 \times 1}$, 即:

$$\tilde{\chi} = \frac{\chi - \mu}{\sqrt{\text{var} + \epsilon}} \quad (1)$$

式中: ϵ 是一个很小的常数, 避免分母为 0。

计算每个像素点 $\chi_{i,j} \in \tilde{\chi}$ 与其他像素点的相似度 $Y_{i,j}$, 并对相似度值归一化, 对于每一个像素点 $\chi_{i,j}$, 计算其他像素点相似度值:

$$Y_{i,j} = \frac{x_{i,j}^2}{4 \left(\frac{1}{n-1} \sum_{k \neq i,j} x_k^2 + \epsilon \right)} + 0.5 \quad (2)$$

式中: $n = H \times W$ 为特征图的像素点数目。相似

度 $Y_{i,j}$ 的计算方式是将 $\chi_{i,j}$ 与其他像素点的平方差进行归一化,并加上一个偏置项 0.5,把相似度映射到 $[0,1]$ 的范围。将原始特征图 χ 与相似度 Y 相乘,得到加权后的特征图 $Z \in \mathbb{R}^{B \times C \times W \times G}$,即: $Z_{i,j} = x_{i,j} y_{i,j}$ 。将加权后的特征图 Z 通过 Sigmoid 激活函数进行归一化,得到最终的输出特征图。simAM 模块是一种用于图像分类任务的自适应注意力机制。它的核心思想是利用相似性信息来调整每个通道的注意力权重,从而提升图像分类的性能。

simAM 模块首先通过两个全局池化操作获取特征图中每个通道的全局平均值和标准差^[18]。对于每个通道,simAM 将其与其他通道之间的相似性定义为该通道与其他通道的余弦相似度,并将这些相似性作为一个矩阵输入一个子网络中。该子网络使用多层感知器(MLP)来学习如何将相似性信息转换为注意力权重^[19]。simAM 通过对输入特征应用学习到的注意力权重进行加权求和,从而生成经过调整的特征表示。

3 实验过程与结果

3.1 实验过程

数据采集设备:外业采集设备包括高清摄像头、平整度仪、集成芯片一体机和采集控制终端等。其中高清摄像头用于采集路面病害原始视频数据,同时可用于记录道路景观图像数据,用于道路病害溯源佐证及沿线设施人工复核;平整度仪记录路面平整度原始数据以及采集里程数据,该设备可挂载在各种不同的 SUV 车体,安装及拆卸方便。较传统检测车而言,具有成本低、轻量化、拆装方便等特点。

数据搜集准备阶段主要包括多源数据采集、数据格式转换、多源数据融合、数据入库以及数据共享^[18]。因采集到的数据格式不统一,需针对不同格式进行统一转换,统一的内容主要有数据格式、命名规范、数据分类和数据标准化等^[21,22]。利用程序化实现多源数据融合,多模态数据无界限衔接工作,最后针对不同源数据进行分层分类存储入库,后期可根据不同的业务需求进行数据共享开放,实现数据流动性。

本文实验过程中验证集包括两大来源:第一大来源为自有数据集 HN-Road-ObjDet,第二大来源为外部公开数据集 CRDDC2022^[20],其中因

CRDDC2022 数据集仅有训练集和测试集两部分,未有验证集数据,现采用随机抽取的方式从训练集中抽取部分数据作为验证集进行模型验证,CRDDC2022 数据集的内容主要涉及道路病害数据的收集和整理。数据共由 7 个数据集组成,其中病害种类主要有裂缝、网裂、修补和坑槽,其中修补和坑槽的病害种类在部分数据集中略有体现,坑槽的标注在该数据集中明确表明存在误标注现象。另外,数据采集来源主要有实地勘测、无人机拍摄、卫星图像等,并且各个图片像素和大小差异较大,该数据集图像质量与现有实际道路采集设备搜集到的图像质量相差甚大。

数据处理-样本标注及样本划分:明确病害类型及常见易混淆的干扰物类型,收集大量的数据集,本文采用 labeling 标注工具进行目标检测框标注,整理生成目标检测数据集 HN-Road-ObjDet,将样本按照不同道路类型分成 6 类:裂缝、破碎板、拼接缝、坑槽、网裂、修补。采集到约 50 090 张图片,通过数据清洗和数据增强共有 60 940 张用于构建数据集,720 000 多个预标注锚框,其中训练集达到 36 564 张,验证集达到 12 188 张,测试集达到 12 188 张。

运行环境:本文实验采用 Windows 10 专业版 64 位操作系统,Python3.10.1 开发语言,Pytorch1.13.0+cu116 深度学习框架,所用显卡为 NVIDIA GeForce RTX3060Ti,500 G SSD 硬盘,32 GB 内存,CUDA 版本为 CUDA 12.3。

因训练的模型既要保证模型的精度,也要保证模型的大小和训练速度,本文选用 YOLOv8 模型和 YOLOv8s.pt 权重文件进行训练,epoch 设置为 300,Batch size 设置为 10,基本学习率设置为 0.01,在训练过程中采用自适应衰减自动调整学习率,置信度设置为 0.25。

图像数据增强:用于进一步丰富训练用样本集合,增加训练后模型的鲁棒性。使用常规增强,包含平移、翻转、旋转、HSV 变换等^[21],来扩充样本的丰富程度;使用畸变扰动增强,来增加模型对相机透镜造成的画面畸变的鲁棒性;使用动态模糊增强,来提升模型对高速运动场景中病害识别的准确性。使用 Mosaic 增强,来丰富检测物的背景,在 BN 计算时一次性计算多张图的数据,提升模型学习效率^[22]。融合多种增强效果如图 4、图 5 所示。




图 4 HSV 变换数据增强效果图

Fig. 4 HSV data augmentation results

模型训练如下(见图6):

(1)依照机器学习模型训练通用法则将自有数据集按照6:2:2的比例进行随机拆分,60%作为训练集使用,剩余40%分别作为测试集和验证集。

(2)将训练集分别提供给初始化YOLOv8模

型进行模型权重训练。

(3)模型训练主要利用已有的初始化模型进行模型新分类权重的训练。

(4)模型训练好之后使用验证集进行模型评估,按照评估结果进行模型调整或者模型部署。

(5)利用测试集进行已有模型的测试,进行模型部署工作。

模型评估:YOLOv8是一种单阶段目标检测算法,采用了不同的网络结构,使用轻量级的模型设计。引入了自动化模型构建技术,通过AutoML实现网络结构,其中模型评估环节主要利用精确率、召回率、IoU和mAP等进行相关指标评估^[23]。

IoU (Intersection over union, 交并比)计算的是“预测的边框”和“真实的边框”的交叠率,即它们的交集和并集的比值。最理想的情况是完全重叠,即比值为1。

精确率是分类正确的样本在所有样本中的数量比例,公式如下:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (3)$$

召回率指真正为正的样本中被正确地预测为正的样本占比,公式如下:

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (4)$$




图 5 Mosaic 数据增强效果图

Fig. 5 Mosaic data augmentation results




图 6 模型训练流程图

Fig. 6 Flow chart of model training

式中:TP表示真正为正的样本预测为正;FP表示真正为负的样本预测为正;FN表示真正为正的样本预测为负。通常情况下,精确率和召回率是相互矛盾的,提高精确率会降低召回率,反之亦然。

置信度(Confidence):介于0~1的值,表示模型对检测到的目标的确信程度。它是通过两个主要因素来计算的,第一个要素是图像中的目标物,预测框位置越准确置信度越高,图像中存在目标的概率越高,反之越低。第二个要素是IoU指标值,IoU越高,预测越准确,置信度也就越高,反之就越低。

AP(Average-precision)表示平均精度,是主流的目标检测模型的评价指标,通常来说一个越好的分类器,AP值越高。mAP(mean Average precision)是多个类别AP的平均值,mAP的大小一定在[0,1]区间,越大越好。另外,mAP@0.5表示IoU=0.5,计算每一个分类所有图片的AP值,然后所有分类求平均mAP值;mAP@0.5:0.95表示在不同的IoU(从0.5到0.95,不包括0.5,步长为0.05)上的平均mAP值。

AP就是PR曲线与坐标轴围成的面积,公式如下:

$$AP = \int_0^1 P(r) dr \quad (5)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (6)$$

式中:C为总类别数目; AP_i 为第*i*类的AP值。

模型调参:YOLOv8调参主要针对超参数优化来改善模型的性能和学习能力,超参数主要有学习率、批次大小、层的数量和大小、正则化参数等,本文主要使用遗传算法(GA)寻找最优的超参数。

遗传算法是用于解决最优化问题的一种搜索算法,执行步骤如下:

(1)随机建立由字符串组成的初始群体。

(2)计算各个体的适应度。

(3)根据遗传概率,利用下述操作产生新群体:①复制,将已有的优良个体复制后添入新群体中,删除劣质个体;②交换,将选出的两个个体进行交换,所产生的新个体添入新群体中;③突变,随机改变某一个体的某个字符后添入新群体中。

(4)反复执行(2)(3)后,一旦达到终止条件,选择最佳个体作为遗传算法的结果。

3.2 结果分析

3.2.1 改进算法分析

基于已有的YOLOv8框架,首先改进的是网络结构,增加了Res2Net模块,该模块的主要作用是对图像特征进行提取,对模型推理中的有效面积(IoU)计算更加精准;其次改进的是算法框架,增加了simAM模块,该模块的主要作用是实现图像中不同病害特征差异最大化,对模型推理中不同病害检测的精确率更高。

算法改进结果对比如下:图7、图8的实验结果证明,在模型训练阶段,增加simAM模块的算法明显比原始YOLOv8算法各项评估指标

($mAP@0.5$ 、 $mAP@0.5:0.95$ 、Precision 以及 Recall)都更好。另外,从整个迭代训练过程的折线图波动性来看,增加了 Res2Net 模块的算法其鲁棒性更强;在模型推理阶段,改进后随机抽取 2 张实例图片进行病害检测,通过柱状图对比可以看

出第一张图的置信度指标由 0.35 提升至 0.57,另一张图指标由 0.88 提升至 0.96,另外,从 2 张推理结果图的预测框位置上对比可以发现,改进后对病害目标的定位也更加精准。




图 7 simAM 实验结果对比

Fig. 7 Experimental comparison of reasoning results with or without simAM




图 8 simAM 推理结果对比

Fig. 8 Comparison diagram of reasoning results with or without simAM

3.2.2 消融实验结果

为了验证更改网络架构为 Res2Net 和增加注意力机制 simAM 对 HN-Road-ObjDet 数据集的提升效果,本文做了消融对比实验,实验结果如表 1 所示。

由表 1 可知,添加 Res2Net 网络架构之后相

较于原始 YOLOv8 网络架构,平均精确度(mAP)提升了 1.6%,精确率提升了 10.4%,召回率提升了 1.8%,说明改进后的网络架构在整体模型评估指标中起到了很大的作用。添加 simAM 无参数机制后相较于原始模型,平均精确度(mAP)提升了 3.5%,精确率提升了 4.8%,召

的模型有明显提升,另外,通过数据统计分析获悉模型在公开数据集表现差的原因主要有:①公开数据集图像质量差,其中主要有像素值低、清晰度低和失真变形等;②公开数据集拍摄角度不准确,71%的数据集拍摄角度为道路街景角度,未拍摄

到路面有效区域;③病害数据标注质量差,其中主要有病害标注不准确和无法辨识的情况,导致结果误判;④模型训练数据集仅有自有数据集,未添加使用公开数据集,导致模型未能学习到公开数据集图像特征和有效权重构建。

表 2 模型验证结果表

Table 2 Model validation results table

数据集	模型	病害类型	图像数	标答数	精确率 ↑	召回率 ↑	mAP@0.5 ↑	mAP@0.5:0.95 ↑
HN-Road-ObjDet	YOLOv8	all		28 600	0.788	0.796	0.796	0.42
		裂缝		9 250	0.789	0.792	0.778	0.361
		破碎板		2 820	0.786	0.772	0.779	0.41
		拼接缝	12 188	1 930	0.831	0.875	0.898	0.490
		坑槽		7 710	0.815	0.783	0.798	0.344
		网裂		3 890	0.766	0.764	0.758	0.431
		修补		3 000	0.738	0.787	0.764	0.392
	simAM-YOLOv8	all		28 600	0.941	0.927	0.954	0.48
		裂缝		9 250	0.926	0.934	0.967	0.484
		破碎板		2 820	0.936	0.924	0.919	0.496
		拼接缝	12 188	1 930	0.971	0.952	0.954	0.497
		坑槽		7 710	0.968	0.938	0.963	0.459
		网裂		3 890	0.925	0.912	0.963	0.467
		修补		3 000	0.918	0.903	0.957	0.479
CRDDC2022	YOLOv8	all		2 674	0.147	0.171	0.074 7	0.030 8
		裂缝		1 749	0.198	0.138	0.080 7	0.031 9
		坑槽	1 211	350	0.088 4	0.128	0.042 1	0.013 7
		网裂		533	0.296	0.25	0.173	0.075 7
		修补		42	0.005 17	0.167	0.003 16	0.002 01
	simAM-YOLOv8	all		2 674	0.369	0.273	0.21	0.073 9
		裂缝		1 749	0.517	0.277	0.292	0.11
		坑槽	1 211	350	0.334	0.435	0.253	0.046 4
		网裂		533	0.494	0.26	0.221	0.085 2
		修补		42	0.131	0.119	0.074 6	0.054 6

注:向上的箭头 ↑ 表示越大越好。

4 结 论

(1)基于 YOLOv8 病害目标检测的核心算法,可实现路面病害特征的快速自动化分析和综合评定。经对比验证,改进后的本文 simAM-YOLOv8 检测算法对路面病害检测相较原网络精确率和召回率均有 10% 以上提升,具有较高的识别精度。

(2)模型测试结果表明:改进后的本文模型各项评估指标均达到预期值,适用于不同类型路面的多病害识别,应用于路面自动化快速检测设备中,可辅助巡检人员完成道路病害智能检测。

(3)本研究仍有一定的局限性:由于样本量有

限,结果的普适性可能受到影响,难以全面反映不同环境和条件下的病害识别,另外,本研究在道路三维非表观病害识别领域尚有欠缺,未来考虑引入更加先进的检测技术和设备以提高病害检测的精度和全面性。

参考文献:

- [1] 罗晖,余俊英,涂所成. 基于深度学习的公路路面病害检测算法[J]. 科学技术与工程, 2022, 22(13): 5329-5305.
Luo Hui, Yu Jun-ying, Tu Suo-cheng. Pavement defect detection algorithm based on deep learning[J]. Science Technology and Engineering, 2022, 22(13):

- 5329-5305.
- [2] Hou Y, Li Q, Zhang C, et al. The state-of-the-art review on applications of intrusive sensing, image processing techniques, and machine learning methods in pavement monitoring and analysis[J]. Engineering, 2021, 7(6): 845-856.
- [3] Cheng H, Wan F, Lei G, et al. GCS-YOLO: a light-weight strawberry disease detection algorithm based on improved YOLOv8[C]//The 5th International Conference on Frontiers Technology of Information and Computer(ICFTIC), Qiangdao, China, 2023: 1071-1076.
- [4] 章世祥, 张汉成, 李西芝, 等. 基于机器视觉的路面裂缝病害多目标识别研究[J]. 公路交通科技, 2021, 38(3): 30-39.
- Zhang Shi-xiang, Zhang Han-cheng, Li Xi-zi, et al. Study on multi-objective identification of pavement cracks based on machine vision[J]. Journal of Highway and Transportation Research and Development, 2021, 38(3): 30-39.
- [5] 陈涵深. 基于深度学习的路面破损检测研究[D]. 杭州: 浙江工业大学信息工程学院, 2020.
- Chen Han-shen. Deep learning for pavement distress detection[D]. Hangzhou: College of Information Engineering, Zhejiang University of Technology, 2020.
- [6] 魏陈浩, 杨睿, 刘振丙, 等. 具有双层路由注意力的 YOLOv8 道路场景目标检测方法[J]. 图学学报, 2023, 44(6): 1104-1111.
- Wei Chen-hao, Yang Rui, Liu Zhen-bing, et al. YOLOv8 with bi-level routing attention for road scene object detection[J]. Journal of Graphics, 2023, 44(6): 1104-1111.
- [7] 侯越, 张慧婷, 高智伟, 等. 基于数据深度增强的路面病害智能检测方法研究及比较[J]. 北京工业大学学报, 2022, 48(6): 622-634.
- Hou Yue, Zhang Hui-ting, Gao Zhi-wei, et al. Research and comparison of intelligent detection methods of pavement distress based on deep data augmentation[J]. Journal of Beijing University of Technology, 2022, 48(6): 622-634.
- [8] 倪昌双, 李林, 罗文婷, 等. 改进 YOLOv7 的沥青路面病害检测[J]. 计算机工程与应用, 2023, 59(13): 305-316.
- Ni Chang-shuang, Li Lin, Luo Wen-ting, et al. Disease detection of asphalt pavement based on improved YOLOv7[J]. Computer Engineering and Applications, 2023, 59(13): 305-316.
- [9] 田鹏, 毛力. 改进 YOLOv8 的道路交通标志目标检测算法[J]. 计算机工程与应用, 2024, 60(8): 202-212.
- Tian Peng, Mao Li. Improved YOLOv8 object detection algorithm for traffic sign target[J]. Computer Engineering and Applications, 2024, 60(8): 202-212.
- [10] Yang L, Zhang R Y, Li L, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]//International Conference On Machine Learning, Vienna, Austria, 2021: 11863-11874.
- [11] Xie J, Wu Z, Zhu R, et al. Melanoma detection based on swin transformer and SimAM[C]//IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference(ITNEC), Xi'an, China, 2021: 1517-1521.
- [12] 韩强. 面向小目标检测的改进 YOLOv8 算法研究[D]. 长春: 吉林大学数学学院, 2024.
- Han Qiang. Research on improved YOLOv8 algorithm for small object detection[D]. Changchun: School of Mathematics, Jilin University, 2024.
- [13] Du Y, Pan N, Xu Z, et al. Pavement distress detection and classification based on YOLO network[J]. International Journal of Pavement Engineering, 2021, 22(13): 1659-1672.
- [14] Jiang P, Ergu D, Liu F, et al. A review of YOLO algorithm developments[J]. Procedia Computer Science, 2022, 199: 1066-1073.
- [15] 邹彦艳, 曹衍芬, 张馨月, 等. 基于 YOLOv8-DSG 的钢铁表面缺陷检测算法[J]. 吉林大学学报: 信息科学版, 2025, 43(1): 116-125.
- Zou Yan-yan, Cao Yan-fen, Zhang Xin-yue, et al. Steel surface defect detection algorithm based on YOLOv8-DSG[J]. Journal of Jilin University(Information Science Edition), 2025, 43(1): 116-125.
- [16] Gao S H, Cheng M M, Zhao K, et al. Res2Net: a new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652-662.
- [17] Zhou Z, Wang Y, Feng C, et al. A moving ferromagnetic target localization method based on YOLO-V3[C]//The 4th International Conference on Intelligent Control, Measurement and Signal Processing(ICMSP), Hangzhou, China, 2022: 205-212.
- [18] 李志慧, 钟涛, 赵永华, 等. 面向车辆自动驾驶的行人跟踪算法[J]. 吉林大学学报: 工学版, 2019, 49(3):

- 680-687.
- Li Zhi-hui, Zhong Tao, Zhao Yong-hua, et al. Pedestrian tracking algorithm for autonomous vehicle driving[J]. Journal of Jilin University(Engineering and Technology Edition), 2019, 49(3): 680-687.
- [19] 宗芳, 齐厚成, 唐明, 等. 基于GPS数据的日出行模式-出行目的识别[J]. 吉林大学学报: 工学版, 2018, 48(5): 1374-1379.
- Zong Fang, Qi Hou-cheng, Tang Ming, et al. Daily travel mode based on GPS data - travel purpose recognition[J]. Journal of Jilin University(Engineering and Technology Edition), 2018, 48(5): 1374-1379. .
- [20] Arya D, Maeda H, Ghosh S K, et al. Rdd2022: a multi-national image dataset for automatic road damage detection[DB/OL]. [2024-04-26]. <https://arxiv.org/abs/2209.08538>.
- [21] Guo Q, Wang Y, Zhang Y, et al. AIE-YOLO: effective object detection method in extreme driving scenarios via adaptive image enhancement[J]. Science Progress, 2024, 107(3): No. 368504241263165.
- [22] Wang H, Li S, Zhang Y, et al. Axle surface defect detection based on YOLOv8[C]//International Conference on Image Processing, Computer Vision and Machine Learning(ICICML), Chengdu, China, 2023: 1001-1005.
- [23] Yuan J, Wan F, Lei G, et al. FEB-YOLOv8: a steel surface defect detection algorithm based on improved YOLOv8s[C]//The 3rd International Conference on Computer Science, Electronic Information Engineering and Intelligent Control Technology(CEI), Wuhan, China, 2023: 629-633.