

基于改进 YOLOv7 的公路路面病害检测算法

罗晖¹, 马治伟¹, 斯成浩¹, 韩岳霖¹, 王亚民²

(1. 华东交通大学信息工程学院, 江西 南昌 330013; 2. 江西路通科技有限公司, 江西 南昌 330013)

摘要: 针对公路路面病害存在类别多、尺度差异大和背景复杂度高等问题, 提出一种改进 YOLOv7 的公路路面病害检测算法。首先, 在颈部网络中引入显示视觉中心模块, 能够充分获取输入特征的全局信息与局部信息, 提高对小目标的特征提取能力。其次, 设计特征融合模块 RFECSP, 通过增强对多类、多尺度病害的特征融合能力, 解决细节信息丢失与受无关区域影响导致检测精度低的问题。最后, 使用 MPDIoU 损失函数提高网络的收敛速度和检测精度。结果表明, 本文算法在 RDD 2020 数据集上取得了良好的效果, 与 YOLOv7 算法相比平均检测精度提升了 3.13%, 且优于 SSD、YOLOv4、YOLOv5 等算法, 对于路面病害具有良好的检测效果, 能够满足对公路路面中裂缝或坑槽类病害的检测要求。

关键词: 病害检测; 显示视觉中心; 感受野; 混合池化; 损失函数

中图分类号: TP391 文献标识码: A

Highway pavement disease detection algorithm based on improved YOLOv7

Luo Hui¹ Ma Zhiwei¹ Si Chenghao¹ Han Yuelin¹ Wang Yamin²

(1. School of Information Engineering, East China Jiaotong University, Nanchang 330013, China; 2. Jiangxi Lutong Technology Co., Nanchang 330013, China)

Abstract: Aiming at the problems of highway pavement distresses, such as the existence of many categories, large scale differences and high background complexity, a highway pavement distress detection algorithm with improved YOLOv7 is proposed. Firstly, the display vision center module is introduced into the neck network, which can fully acquire the global and local information of input features and improve the feature extraction ability for small targets. Second, the feature fusion module RFECSP is designed to solve the problem of low detection accuracy due to the loss of detail information and the influence of irrelevant regions by enhancing the feature fusion ability for multi-class and multi-scale diseases. Finally, the MPDIoU loss function is used to improve the convergence speed and detection accuracy of the network. The results show that the algorithm in this paper achieves good results on the RDD 2020 dataset, improves the average detection accuracy by 3.13% compared with the YOLOv7 algorithm, and outperforms the algorithms such as SSD, YOLOv4, YOLOv5, etc. The algorithm has a good effect of detecting roadway pavement damage, and it can satisfy the requirements of detecting the cracks or potholes type of damage in highway pavements.

Key words: Disease detection; Explicit visual center; experience the wild; Mixed pooling; Loss function

收稿日期: 2024-04-22

基金项目: 国家自然科学基金资助项目(62262021)

公路交通是国家交通运输体系的关键构成部分,对于推动国家经济发展和社会进步扮演着至关重要的角色。然而,随着公路里程的快速增长和运输业的持续发展,公路承受的压力和磨损也在不断加大,导致出现多种类型的病害。常见的病害类别有裂缝、变形和表面损坏三大类别^[1],这些病害不仅会影响道路外观和驾驶体验,还可能在极端情况下引发重大交通事故^[2]。因此,及时发现路面病害,是保障公路交通系统安全畅通、提升服务质量的关键任务。

在公路路面病害检测领域,虽然传统的人工检测方法一直被采用,但是常常受限于操作人员的技术经验,存在低效率和高成本的问题,难以满足日益增长的检测需求。近年来基于传统图像处理的检测技术取得了显著的发展,由于路面病害通常表现为不同的颜色或纹理特征,因此可以利用自动阈值分割技术将病害区域与路面背景分离,从而实现病害检测。Chen等^[3]通过预处理算法结合全局阈值和局部阈值对图像进行分割,利用滑动窗口和最大类间偏差来识别出潜在的病害区域。Safaci等^[4]通过改进加权邻域像素分割算法识别路面病害,采用高斯累积密度函数作为自适应阈值,提高了在噪声环境下的检测效果。Peng等^[5]通过随机结构森林的三阈值来对路面进行裂缝检测,通过获得通道特征信息和成对差异特征来细化目标特征,使用随机结构森林和形态学技术预测局部裂缝斑块。上述方法虽然取得了一些效果,但是在实际检测中容易受到环境影响,导致检测性能不稳定,并且难以泛化到不同类型的路面和不同种类的病害,无法满足当前公路路面检测的需求。

近年来,随着卷积神经网络的发展,基于深度学习的目标检测方法由于具备自动学习特征表示的能力,在不同场景和条件下展现了强大的性能和泛化能力,因此在公路路面病害检测中也得到了广泛应用。例如,沈思远等^[6]提出一种改进的YOLOv5算法,通过引入坐标注意力机制、重影混洗卷积和设计特征融合网络,有效提高了裂缝特征关注度和特征融合能力。Yang等^[7]提出基于改进YOLOv5算法的轻量级网络PDNet,通过提出跨层加权级联聚合网络、设计GhostC3和ShuffleConv模块以及选择CIoU损失函数,提高了公路路面病害检测的效率。Luo等^[8]提出了STrans-YOLOX算法,通过引入全局注意力引导模块和 α -IoU-NMS后处理策略,提高了长距离依赖性和多尺度裂缝特征融合能力,实现了对遮挡和重叠物体的精确抑制。Dong^[9]提出了基于注意力机制和多尺度特征融合的路面裂缝检测算法,通过不对称的编解码结构、双注意力机制的多尺度扩展残差网络以及基于注意力机制的特征金字塔模块,能够精准地识别和提取裂缝信息。周双喜等^[10]利用注意力机制对YOLOv5算法进行改进,解决了传统路面裂缝检测实时性差、准确率低的问题。刘永胜等^[11]通过使用MobileNetV2网络和引入SENet注意力机制改进SSD算法,提高了网络的识别能力。基于上述分析,当前阶段的公路路面病害检测方法虽然在准确性方面取得了一定的效果,但仍然面临着诸多挑战,例如难以在复杂背景中准确识别和定位小目标,以及受背景区域影响导致检测精度低等问题。

因此,本文选择改进YOLOv7算法来进一步提高对公路路面病害的检测精度。首先,在颈部网络中引入显式视觉中心模块,基于层间特征交互和层内特征调节规则,增强对小目标的特征提取能力。其次,设计一种新的特征融合模块RFECSP,通过感受野扩展模块增大感受野,解决由于多次池化导致细节信息丢失的问题,同时利用混合池化模块提高在复杂背景下对不同尺度目标的检测能力。最后使用MPDIoU损失函数,进一步提高算法的收敛速度和检测精度。

研究基于深度学习的目标检测方法应用在公路路面病害检测中,不仅有助于推动公路养护管理的智能化和自动化,还有助于推动相关领域的科技发展,同时保障了公路的安全性和通行性,具有重要的研究价值和社会意义。

用于获取深层特征的全局信息。与空间 MLP 相比，通道 MLP 能够在满足视觉任务要求的同时降低其计算复杂性。由图 2 可知，MLP 模块的输入是基于深度卷积模块的输出，随后进行通道缩放和 DropPath，提高特征的泛化能力和鲁棒性。具体过程为：

$$\tilde{X}_{in} = DConv(GN(X_{in})) + X_{in} \quad (1)$$

$$MLP(X_{in}) = CMLP(GN(\tilde{X}_{in})) + \tilde{X}_{in} \quad (2)$$

其中， X_{in} 为输入特征， \tilde{X}_{in} 为基于深度卷积的输出， GN 为组归一化， $DConv$ 为深度卷积， $CMLP$ 为通道 MLP， $MLP(X_{in})$ 为输出特征信息。公式中为了表达简洁，省略了通道缩放和 DropPath。

LVC 则是具有固有字典的编码器，用于聚集层内局部区域特征信息。其结构如图 2 所示，其中一部分是固有码书，另一部分是可学习视觉中心的比例因子。来自 Stem 模块的特征 X_{in} 通过卷积层进行编码。然后，通过 CBR 模块处理后在码书中使用比例因子 s 依次使 \tilde{x}_i 和 b_k 映射相应的位置信息。随后，通过全连接层以预测突出显示关键类别的特征信息。最后，来自全连接层的输出信息和 X_{in} 特征进行通道级乘法和执行通道逐元素相加操作，其过程可表示为：

$$LVC(X_{in}) = X_{in} \oplus Z \quad (3)$$

$$Z = X_{in} \otimes (\delta(Conv(e))) \quad (4)$$

$$e = \sum_{k=1}^K \phi(e_k) \quad (5)$$

$$e_k = \sum_{i=1}^N \frac{e^{-s_k \|\tilde{x}_i - b_k\|^2}}{\sum_{j=1}^K e^{-s_k \|\tilde{x}_i - b_k\|^2}} (\tilde{x}_i - b_k) \quad (6)$$

其中， \tilde{x}_i 为第 i 个像素点， b_k 为第 k 个可学习的视觉码字， s_k 为第 k 个比例因子， $\tilde{x}_i - b_k$ 为关于每个像素位置相对码字的信息， K 表示视觉中心的总数， N 为输入特征的总空间数， e_k 第 k 个码字的图像信息， e 为 k 个码字的图像完整信息， Z 为全连接层的输出信息， $Conv$ 为 1×1 卷积， δ 为缩放因子系数， LVC 则为输出特征信息。

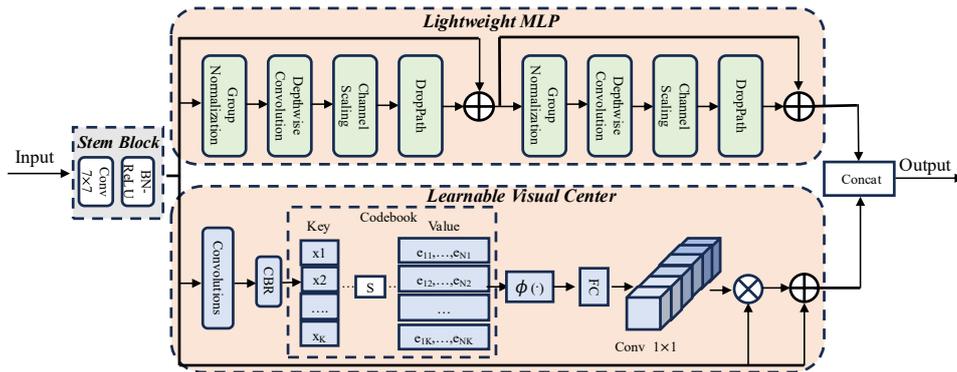


图 2 EVC 模块结构图

Fig. 2 Structure of EVC module

2.2 RFECSP 模块

在 YOLOv7 算法中，由于 SPPCSPC 模块中采用金字塔池化（Spatial Pyramid Pooling, SPP）^[17]增大网络感受野，导致图像分辨率降低，从而可能会出现目标细节信息被忽略或丢失的问题。并且在面对复杂背景下长而窄的裂缝目标时，使用最大池化可能会使许多与裂缝无关的区域信息被错误地提取到特征信息中，导致检测效果较差。因此，本文结合感受野扩

展模块(Receptive Field Expansion Module, RFEM)^[18]和混合池化模块(Mixed Pooling Module, MPM)^[19]设计了一种新的特征融合模块,称为 RFECSP,其网络结构如图3所示。该模块共有三条分支,其中第一条分支使用 RFEM 模块增大网络感受野,解决由于池化导致细节信息丢失的问题。第二条分支中多次使用 MPM 模块,主要解决复杂背景下检测过程中受无关区域影响的问题。最后一条分支能够保持原始感受野不变,从而保证原始特征信息的优势。然后将三条分支的输出特征图进行融合,之后使用 CBS 模块进一步提取丰富的特征信息。

RFEM 模块如图4所示,输入图像经过不同空洞率的空洞卷积处理后进行通道拼接,最后通过卷积层调整通道数。该模块通过并行和级联结构,能够捕获平衡的非局部上下文信息和局部目标特征,解决小目标局部语义缺失的问题。同时将各层特征进行叠加与重用,解决空洞卷积带来的信息丢失问题,并且能够保证每次特征图融合时保持原始特征信息的优势。其各层输出公式如下:

$$R_1 = Dconv(F) \quad (7)$$

$$R_2 = Dconv(Convcat(R_1; F)) \quad (8)$$

$$R_3 = Dconv(Convcat(R_2; cat(R_1; F))) \quad (9)$$

$$P = Conv(cat(R_3; cat(R_2; cat(R_1; F)))) \quad (10)$$

其中, F 表示 RFEM 层的输入特征, $R_i (i=1,2,3)$ 表示中间变量, $Dconv$ 表示卷积核为 3×3 、空洞率为 2、4、8 的空洞卷积, $Conv$ 表示 1×1 卷积, cat 表示沿通道拼接, P 则表示 RFEM 模块的输出特征。

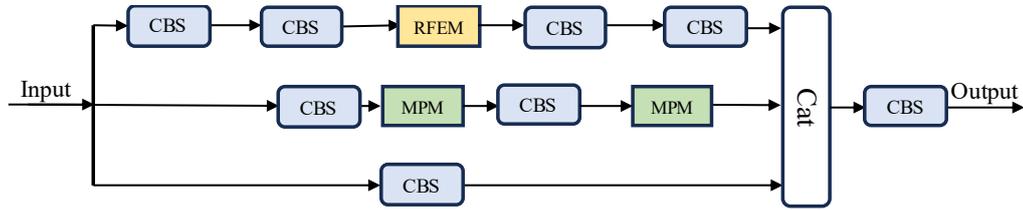


图3 RFECSP 模块结构图

Fig. 3 Structure of RFECSP module

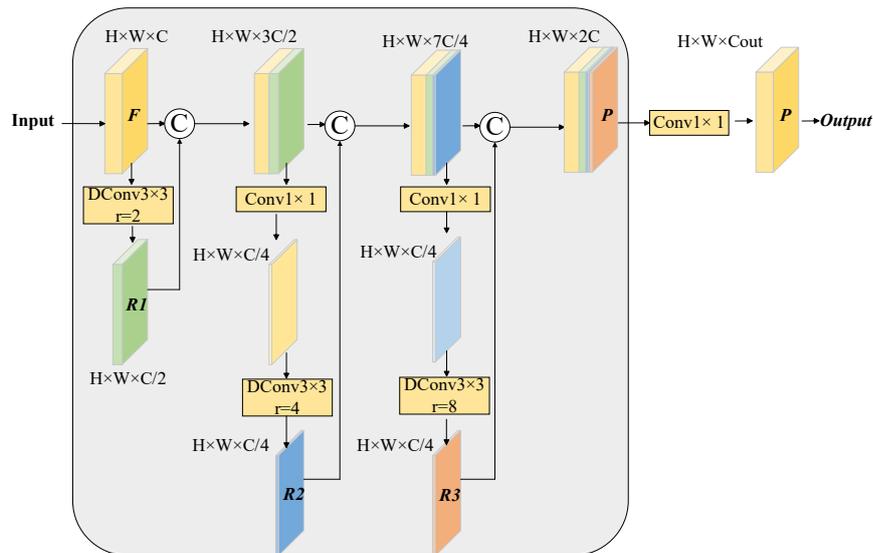


图4 RFEM 模块结构图

Fig. 4 Structure of RFEM module

MPM 模块则是由 PPM (Pyramid pooling module)^[20]和 SPM (Strip Pooling Module)^[19]两条分支组成, 通过不同内核形状的池化操作兼顾长条形与非长条形目标, 能够捕获不同位置之间的短程和长程依赖关系, 从而融合不同类型的上下文信息, 解决复杂背景下无关区域信息的干扰。如图 5 所示, 在 PPM 分支中, 输入图像经池化处理对特征图进行上采样, 随后将特征图融合得到输出特征, 并且获得不同位置之间的短程依赖关系。对于 SPM 分支, 使用水平、垂直方向的条形池化从不同空间维度收集长程依赖关系, 即对于图中的每个空间位置, 编码全局水平和垂直信息, 用其平衡自身权重进行特征细化, 从而能够捕捉局部上下文信息和防止无关区域的影响, 这对于路面裂缝检测是非常重要的。

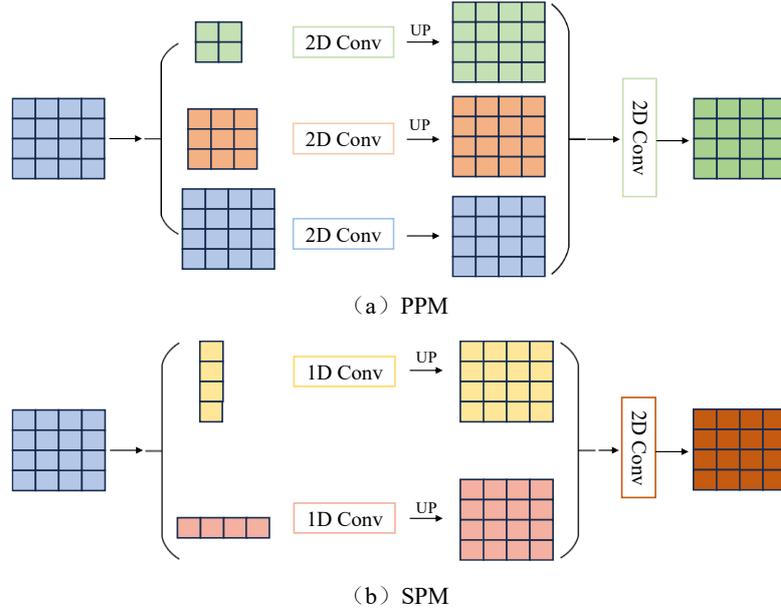


图 5 MPM 模块结构图

Fig. 5 Structure of MPM module

2.3 损失函数改进

YOLOv7 采用 CIoU^[21]为边界框回归损失函数, 但处理具有相同宽高比但宽度和高度完全不同的预测框与真实框时, CIoU 的优化效果并不明显, 且计算过程较为复杂。而本文使用 MPDIoU^[22]为边界框回归损失函数, 它基于最小点距离来进行计算, 综合考虑重叠或非重叠区域、中心点距离以及宽度和高度的偏差等因素, 能够直接最小化预测框与真实框之间的左上角和右下角点距离, 更准确地比较两个边界框的相对位置和大小关系, 从而提高边界框回归的准确性和效率。同时简化计算过程, 进一步提高网络收敛速度。具体表示为:

$$L_{MPDIoU} = 1 - MPDIoU \quad (11)$$

$$MPDIoU = \frac{A \cap B}{A \cup B} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \quad (12)$$

$$d_1^2 = (x_1^B - x_1^A)^2 + (y_1^B - y_1^A)^2 \quad (13)$$

$$d_2^2 = (x_2^B - x_2^A)^2 + (y_2^B - y_2^A)^2 \quad (14)$$

其中, A 、 B 为预测框和真实框, (x_1^A, y_1^A) 、 (x_2^A, y_2^A) 为 A 的左上角和右下角的点坐标, (x_1^B, y_1^B) 、 (x_2^B, y_2^B) 为 B 的左上角和右下角的点坐标, w 、 h 为输入图像的宽度和高度。

3 实验训练与结果分析

3.1 公路路面病害数据集

本文用于训练网络模型的数据集来源于 RDD 2020^[23-25], 该数据集包括横向裂缝、纵向

裂缝、网状裂缝和坑槽四种类型病害，总计 10500 张图片。实验中将横向和纵向裂缝视为同一种病害，称为条形裂缝，标记为 D00，而网状裂缝和坑槽分别被标记为 D20 和 D40。整个数据集按照 8: 1: 1 的比例分为训练集、验证集和测试集，具体数据集示例如图 6 所示。



图 6 路面病害数据集示例图

Fig. 6 Example of pavement distress datasets

3.2 实验环境设置

实验中使用 Windows 10 操作系统，基于 Python 语言的 PyTorch 深度学习框架实现。具体实验环境配置如表 1 所示。

在实验训练阶段，为了减少模型训练时间和充分利用迁移学习，采用 YOLOv7 在 PASCAL VOC 数据集上的预训练权重来初始化参数，训练中使用随机梯度下降 (SGD) 优化算法，初始学习率设置为 0.001，并采用余弦退火法进行学习率衰减，权重衰减系数为 0.0005。在实验初始的 50 个 epoch 中，冻结主干网络，将批处理大小设置为 8 进行训练，随后解冻主干网络，将批处理大小调整为 4，直至训练结束。在整个模型训练过程中，输入图片的尺寸统一处理为 640×640，并采用 Mosaic 进行数据增强，提高网络模型的性能和泛化能力。

表 1 实验环境及配置

Table 1 Experimental environment and configuration

实验环境	实验配置
操作系统	Windows 10, 64 位
CPU	Intel i7-7800X
GPU	NVIDIA GeForce RTX 2080
内存	32G
硬盘	256G
显卡驱动	CUDA 10.0

3.3 评价指标

为了验证改进算法在路面病害检测任务中的有效性，使用以下评价指标：平均精度 (Average Precision, AP)、均值平均精度 (Mean Average Precision, mAP)、F1-score、FPS 以及网络参数量大小 Params Size(MB)。

在目标检测任务中，AP 是衡量目标检测模型性能的重要指标，它反映了模型在某一类别上的精确率和召回率的综合表现，其计算公式如下：

$$AP = \int_0^1 P(R) dR \quad (15)$$

其中， P 为准确率， R 为召回率，其相关公式为：

$$P = \frac{TP}{TP + FP} \quad (16)$$

$$R = \frac{TP}{TP + FN} \quad (17)$$

其中， TP 为真正例 (网络模型正确检测的病害数量)， FP 为假正例 (模型错误标记为病

害的数量), FN 为假负例(实际病害未被检测到的数量)。

由于我们需要评估模型在多个类别上的性能,所以需要使用 mAP 这一评价指标。它是所有类别 AP 值的平均值,综合了模型在各个类别上的性能表现,是最常用的衡量模型整体性能的指标,其相关公式如下:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (18)$$

其中, n 为类别总数, AP_i 为第 i 个类别的 AP 值。

$F1$ -score 则是精确率和召回率的调和平均数,能够提供更全面、更准确的评估,其计算公式如下:

$$F1 - score = 2 * \frac{P * R}{P + R} \quad (19)$$

FPS 是每秒传输帧数,是用来评估网络模型的检测速度,其计算公式为:

$$FPS = \frac{FrameNum}{ElaspedTime} \quad (20)$$

其中, $FrameNum$ 表示处理的图像数量, $ElaspedTime$ 表示处理图像所花费的时间。

3.4 消融实验

为了验证改进部分在网络模型中的有效性,本文在 YOLOv7 算法的基础上逐次添加每个改进模块,对 EVC 模块、RFECSP 模块以及 MPDIoU 损失函数进行消融实验,实验结果如表 2 所示。

表 2 消融实验结果对比
Table 2 Comparison of ablation experiment results

Model	AP/%			mAP/%	Params/M	FPS
	D00	D20	D40			
YOLOv7	48.35	64.67	56.55	56.52	37.62	32.43
YOLOv7+EVC	49.51	64.89	58.44	57.61	41.82	24.79
YOLOv7 + EVC+ RFECSP	50.38	65.51	61.27	59.05	41.31	22.52
YOLOv7 + EVC+ RFECSP+ MPDIoU	50.59	65.94	62.41	59.65	41.31	23.03

由表 2 可知, YOLOv7 算法在路面病害数据集上的 mAP 为 56.52%。而在网络引入 EVC 模块后 mAP 提高了 1.09%,证明 EVC 模块能够通过调节层内特征,获取更丰富的语义信息,提高对小目标的特征提取能力。然后将网络中的 SPPCSPC 模块替换为 RFECSP 模块后 mAP 提高了 1.44%,证明 RFECSP 模块能够保留输入图像的细节信息,有效提升网络在复杂背景下的特征提取能力。最后使用 MPDIoU 作为边界框回归损失函数,能够将网络的 mAP 提高 0.60%,说明 MPDIoU 函数通过考虑目标特征的直径和交集区域,综合更全面的空间信息,能够提高网络模型的检测性能。消融实验表明:相比较原始算法 YOLOv7,本文所提出的改进算法通过引入更高效的网络模块和边界框回归损失函数,在小幅增加网络参数量和降低检测速度的前提下,显著提高了检测精度,改进后算法的 mAP 提高了 3.13%,能够证明本文提出的改进算法的有效性。

网络模型的性能可以通过精确-召回率 (Precision-Recall, P-R) 曲线来准确且直观地评估。如图 7 所示,通过对比算法改进前后的 P-R 曲线图,可以清晰地观察到本文提出的算法在路面病害识别方面的表现明显优于原始的 YOLOv7 网络。这一优势不仅体现在精度的提升上,还体现在召回率的增长上,从而验证了本文算法在路面病害识别任务中的优越性能。

图 8 是改进前后 YOLOv7 算法的 $F1$ -score 曲线的比较。 $F1$ -score 的取值范围为 0 到 1,其中 1 表示模型的输出最好,即精确率和召回率都达到了最高;而 0 则表示模型的输出结果

最差。从图中可以看出,与原始的 YOLOv7 相比,改进后的算法提高了所有类型的 F1-score。

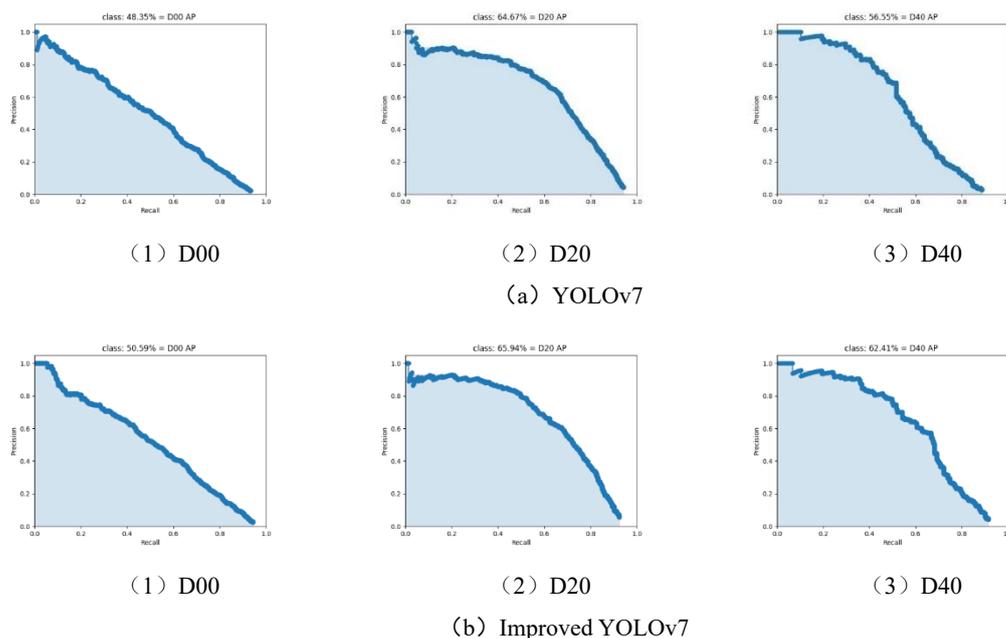


图 7 改进前后的 YOLOv7 算法病害检测 P-R 曲线

Fig. 7 P-R curve of YOLOv7 algorithm for disease detection before and after improvement

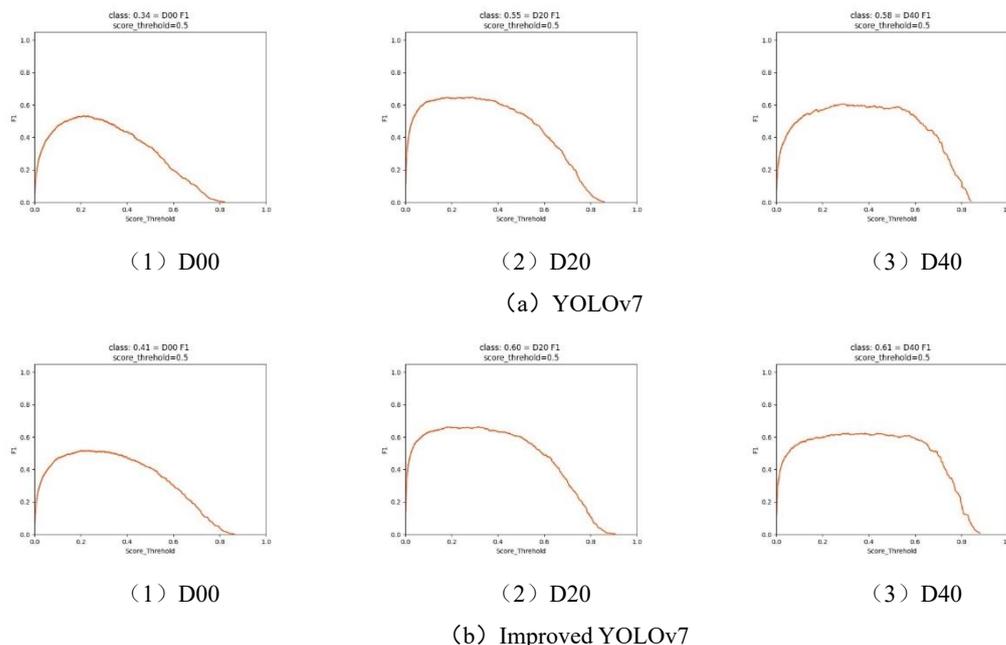


图 8 改进前后的 YOLOv7 算法病害检测 F1-score 曲线

Fig. 8 F1-score curve of YOLOv7 algorithm for disease detection before and after improvement

3.5 对比试验

本文选用 SSD、RetinaNet、YOLOv3、YOLOv4、YOLOv5-l、YOLOv7 等六种算法,对同一批数据集进行测试,然后对比不同网络的性能与检测结果,实验结果如表 3 所示。

根据表 3 实验结果可知,与其他几种主流的目标检测模型相比,改进后 YOLOv7 算法的 mAP 达到了 59.65%,在检测精度方面展现了较大的优势。虽然 YOLOv4 算法对 D20 类病害的检测精度最高,达到了 67.55%,但是在面对其他类病害时,并没有达到理想的检测

效果。同时在网络参数量方面, 相比较于 SSD、RetinaNet 以及 YOLOv7 目标检测算法, 改进后 YOLOv7 算法并没有表现出较大的优势, 但是也保持着一个合理的网络参数量水平, 能够在检测精度与网络复杂度之间达到良好的平衡。其他算法虽然在检测精度方面有着不错的效果, 但同时网络参数量也随之增加。因此, 在能够保证检测精度和网络参数量的前提下, 本文改进后的 YOLOv7 算法综合性能更好, 能够有效应用于公路路面病害检测。其中图 9 能够直观地呈现不同目标检测模型性能实验对比的详细结果。

图 10 为不同目标检测算法对 RDD 数据集的效果检测图, 图中红、绿、蓝框分别代表 D00、D20、D40。如图 10 所示, 其他几种算法在各类病害方面均存在一定的漏检现象, 而改进后的 YOLOv7 算法, 通过添加 EVC 模块和 RFECSP 模块, 增强了对小目标特征信息的提取能力和消除了无关区域对病害检测的影响, 检测效果明显优于其他目标检测模型。

表 3 不同网络的性能对比

Table 3 Performance comparison of different networks

Model	Backbone network	AP/%			mAP/%	Params/MB
		D00	D20	D40		
SSD	VGG-16	36.84	65.06	50.39	50.76	26.29
RetinaNet	ResNet-50	31.82	65.54	57.11	51.49	37.97
YOLOv3	Darknet-53	42.97	61.86	51.56	52.33	61.95
YOLOv4	CSPDarknet-53	45.55	67.55	52.99	55.36	64.36
YOLOv5-l	CSPDarknet-53	45.37	61.68	58.45	55.17	47.06
YOLOv7	CSPDarknet	48.35	64.67	56.55	56.52	37.62
Improved YOLOv7	CSPDarknet	50.59	65.94	62.41	59.65	41.31

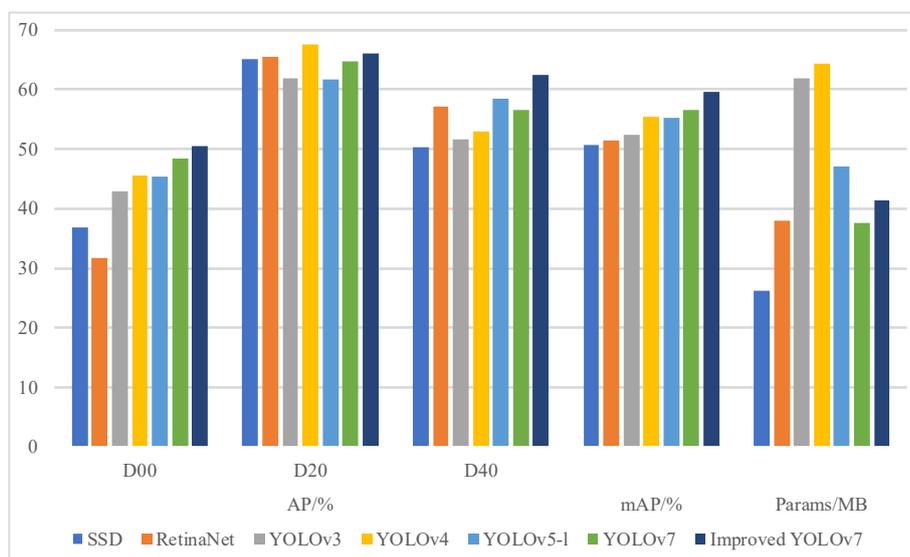
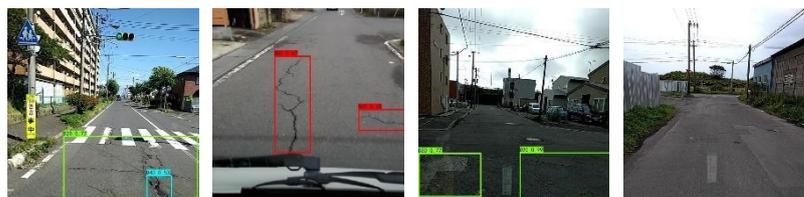


图 9 不同目标检测网络性能对比图

Fig. 9 Comparison of performance of different target detection networks

SSD



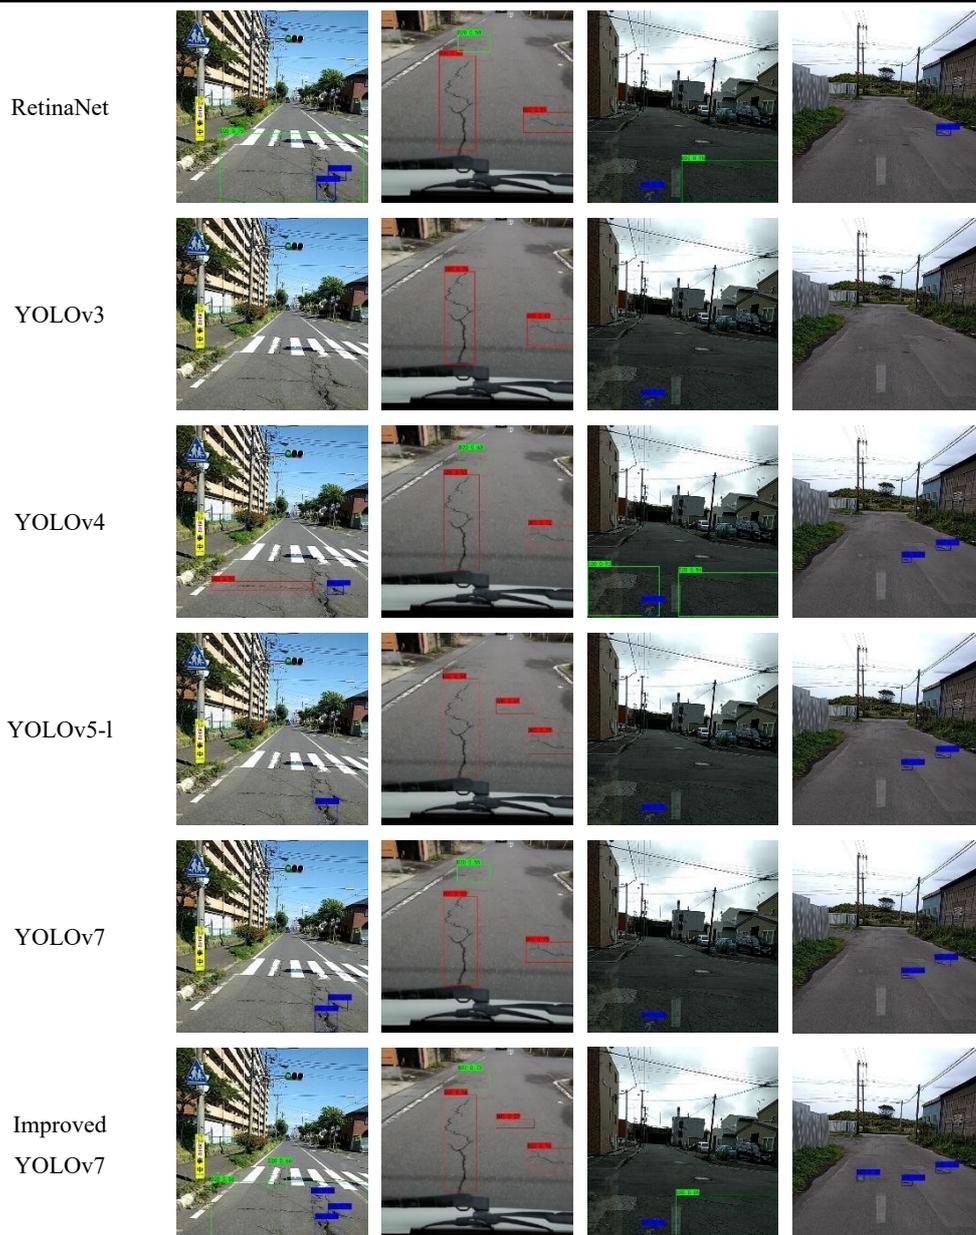


图 10 不同模型检测效果图

Fig. 10 Graph of detection effect of different models

4 结论

本文设计了一种基于改进 YOLOv7 的公路路面病害检测算法，以满足公路路面病害检测的需求，得出以下结论：

1) 通过引入 EVC 模块增强对小目标的特征提取能力，并针对细节信息丢失与受无关区域影响导致检测精度低的问题设计了 RFECSP 模块，最后使用 MPDIoU 损失函数提高算法的收敛速度和准确度。

2) 实验结果显示，改进后的 YOLOv7 算法对路面病害的平均检测精度可达到 59.65%，相较 YOLOv5-l、YOLOv7 算法分别提升了 4.48%和 3.13%，能够有效识别路面病害，适用于公路路面病害检测。

3) 研究结果表明，本文改进后的算法虽然在检测精度方面达到了不错的效果，但是增加了网络模型大小，同时网络的检测速度也有所降低。因此，在未来将继续思考如何在减小

模型大小和提高算法检测速度的情况下提高检测精度。

参考文献

- [1] 杨丽君.高等级公路路面常见病害及养护措施研究[J].工程建设与设计,2023(24):199-201.
YANG L J. Study on Common Diseases and Maintenance Measures of High-Grade Highway Pavements[J]. Construction and Design for Engineering,2023(24):199-201.
- [2] 梁云燕.高速公路路基路面病害的科学检测及预防养护方法[J].四川建材,2023,49(10):183-185.
LIANG Y Y. Scientific detection and preventive maintenance method of highway roadbed pavement disease[J]. Sichuan Building Materials,2023,49(10):183-185.
- [3] CHEN C, SEO H, JUN C H, et al. A potential crack region method to detect crack using image processing of multiple thresholding[J]. Signal, Image and Video Processing, 2022, 16(6): 1673-1681.
- [4] SAFAEI N, SMADI O, SAFAEI B, et al. Efficient road crack detection based on an adaptive pixel-level segmentation algorithm[J]. Transportation Research Record, 2021, 2675(9): 370-381.
- [5] PENG C, YANG M, ZHENG Q, et al. A triple-thresholds pavement crack detection method leveraging random structured forest[J]. Construction and Building Materials, 2020, 263: 120080.
- [6] 沈思远,华蓓,黄汝维.改进 YOLOv5 的路面裂缝检测模型研究[J].电子测量技术,2023,46(21):132-142.
SHEN S Y, HUA B, HUANG R W. Resea-rch on improved YOLOv5 pavement crack detection model[J]. Electronic Measurement Technology,2023,46(21):132-142.
- [7] YANG Z, LI L, LUO W. PDNet: Improved YOLOv5 nondeformable disease detection network for asphalt pavement[J]. Computational Intelligence and Neuroscience, 2022, 2022.
- [8] LUO H, LI J, CAI L, et al. STrans-YOLOX: Fusing swin transformer and YOLOX for automatic pavement crack detection[J]. Applied Sciences, 2023, 13(3): 1999.
- [9] DONG X. Pavement Crack Detection based on Attention Mechanism and Multi Features Fusion[C]//2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA). IEEE, 2022: 8-13.
- [10] 周双喜,杨丹,潘远,等.基于注意力机制的 YOLOv5 路面裂缝检测与识别[J/OL].华东交通大学学报:1-13.
ZHOU S X, YANG D, PAN Y, et al. Detection and recognition of YOLOvS pavement cracks based on attention mechanism [J/OL]. Journal of East China Jiaotong University:1-13.
- [11] 刘永胜,熊吉光,游志杰,等.基于改进 SSD 算法的结构表观裂缝病害检测[J].华东交通大学学报,2023,40(06):1-7.
LIU Y S, XIONG J G, YU Z J, et al. Str-uctural Apparent Crack Disease Detection Based on Improved SSD Algorithm[J]. Journalof East China Jiaotong University,2023,40(06):1-7.
- [12] WANG C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2023: 7464-7475.
- [13] LIU S, QI L, QIN H, et al. Path aggregate-on network for instance segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 8759-8768.
- [14] QUAN Y, ZHANG D, ZHANG L, et al. Centralized feature pyramid for object detection[J]. IEEE Transactions on Image Processi-ng, 2023.
- [15] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detect-ion[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2117-2125.
- [16] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. Mlp-mixer: An all-mlp architecture for vision[J]. Advances in neural information processing systems, 2021, 34: 24261-24272.
- [17] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.
- [18] HAN Y, LIAO J, LU T, et al. KCPNet: Knowledge-driven context perception networks for ship detection in infrared imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 61: 1-19.
- [19] HOU Q, ZHANG L, CHENG M M, et al. Strip pooling: Rethinking spatial pooling for scene

- parsing[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 4003-4012.
- [20] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2881-2890.
- [21] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]//Proceedings of the AAAI conference on artificial intelligence. 2020, 34(07): 12993-13000.
- [22] SILIANG M, YONG X. Mpdious: a loss for efficient and accurate bounding box regression[J]. arXiv preprint arXiv:2307.07662, 2023.
- [23] ARYA D, MAEDA H, GHOSH S K, et al. RDD2020: An annotated image dataset for automatic road damage detection using deep learning[J]. Data in brief, 2021, 36: 107133.
- [24] MANDAL V, MUSSAH A R, ADU-GYAMFI Y. Deep learning frameworks for pavement distress classification: A comparative analysis[C]//2020 IEEE International Conference on Big Data (Big Data). IEEE, 2020: 5577-5583.
- [25] ARYA D, MAEDA H, GHOSH S K, et al. Transfer learning-based road damage detection for multiple countries[J]. arXiv preprint arXiv:2008.13101, 2020.



第一作者: 罗晖 (1969—), 男, 教授, 硕士, 研究方向为深度学习、目标检测、语义分割。
E-mail:lh_jxnc@163.com。



通信作者: 马治伟 (1998—), 男, 硕士研究生, 研究方向为目标检测。E-mail:mzw_37@163.com。