

DOI:10.19651/j.cnki.emt.2517890

非结构化道路坑洼检测的YOLOv7 算法优化

曲雪莲 周福强 谷玉海 王少红

(北京信息科技大学现代测控技术教育部重点实验室 北京 100192)

摘要: 在非结构化道路环境中,及时准确地检测道路坑洼对于保障交通安全至关重要。当前检测算法在复杂场景中存在漏检和精度不足的问题。为提升检测性能,提出了一种基于YOLOv7算法的改进方法。首先通过引入增强的分层多尺度特征融合模块,优化特征提取能力;其次加入高效通道注意力机制,提高模型对目标区域的关注度;最后使用深度可分离卷积减少计算量,提高检测效率。改进后的模型在自制数据集上进行验证,与现有的YOLOv7x、YOLOv7-d6、YOLOv5x和YOLOv5m模型进行对比测试,并将改进后的模型进行公开数据集的迁移学习,采用精确率、召回率(R)、平均精度均值、参数量和每秒帧数作为评估指标。实验结果表明,改进模型在精确率、召回率和平均精度均值上分别提升了5.47%、4.42%和6.65%,在检测速度上也保持了较高的效率;与常用目标检测模型对比性能优异;进行公开数据集的迁移学习后,精确率、召回率和平均精度均值得到进一步提升。这一改进显著提升了模型的检测性能和鲁棒性,不仅增强了交通安全保障能力,也为无人驾驶提供了可靠的技术支持。

关键词: 非结构化道路;目标检测;YOLOv7 算法;增强分层多尺度融合

中图分类号: TP391.4; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

Optimized YOLOv7 algorithm for unstructured road pothole detection

Qu Xuelian Zhou Fuqiang Gu Yuhai Wang Shaohong

(Key Laboratory of Modern Measurement & Control Technology, Ministry of Education,
Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: Timely and accurate detection of road potholes in unstructured environments is crucial for ensuring traffic safety. Current detection algorithms face challenges related to missed detections and insufficient accuracy, particularly in complex scenarios. To enhance detection performance, an improved approach based on the YOLOv7 model is proposed. This method incorporates several enhancements: first, an enhanced hierarchical multi-scale fusion module is introduced to optimize feature extraction capabilities; second, the integration of an efficient channel attention mechanism enhances the model's focus on critical target regions; finally, depthwise separable convolutions are employed to reduce computational complexity while maintaining high detection efficiency. The improved model was validated on the self-made dataset, compared with the existing YOLOv7x, YOLOv7-d6, YOLOv5x and YOLOv5m models, and the improved model was transferred to the public dataset. The evaluation metrics used include precision, recall (R), mean average precision, parameter count, and frames per second. The experimental results show that the improved model improves the precision, recall and average accuracy by 5.47%, 4.42% and 6.65%, respectively, and maintains a high efficiency in the detection speed. Compared with commonly used object detection models, the performance is excellent; after the transfer learning of public datasets, the precision, recall, and average accuracy are worth further improving. This improvement significantly enhances the detection performance and robustness of the model, not only strengthening the ability to ensure traffic safety, but also providing reliable technical support for autonomous driving.

Keywords: unstructured road; object detection; YOLOv7 algorithm; enhanced hierarchical multi-scale fusion

0 引言

道路坑洼作为非结构化道路常见的路面损坏形式之一,不仅影响行车安全,还可能导致车辆损坏,增加维修成

本^[1]。因此及时准确地检测道路坑洼尤为重要。在道路坑洼检测的研究领域,早期的研究主要依靠人工视觉检查和传统的结构化光扫描技术^[2]。这些方法通常涉及现场工作人员目视检查道路状况,记录坑洼的位置和大小,这种方法

不仅耗时耗力,而且受主观判断影响较大,一致性和准确性难以保证。结构化光扫描技术虽然能够提供精确的三维数据,但其设备昂贵、操作复杂,且在户外环境下受光照和天气条件的影响较大,限制了其在道路坑洼检测中的广泛应用。

随着数字图像处理技术的发展,2D 图像处理技术^[3]开始被引入道路坑洼检测领域。这些技术包括对彩色或灰度图像进行对比度增强等预处理操作,以提高图像中坑洼特征的可识别性,例如 Koch 等^[4]在 2011 年通过直方图基阈值分割和形态学操作来检测道路坑洼。预处理后的图像会经过分割,利用边缘检测、形态学操作和直方图阈值法等手段将受损的道路区域(前景)与未受损的道路区域(背景)分离,Ryu 等^[5]在 2015 年通过分析几何属性和使用有序直方图交集方法来提取潜在坑洼区域。分割得到的坑洼候选区域随后会使用几何或纹理特征进行进一步的提取和验证,最终通过后处理步骤对检测结果进行优化,提高检测的准确性和鲁棒性。然而,尽管这些方法成本低且易于实现,但 Jahanshahi 等^[6]提出它们在不同光照条件下的性能会有显著差异,容易受到光照和天气等环境因素的影响,这限制了它们在实际中的应用。

随后,研究者们开始探索 3D 点云技术^[7]以克服 2D 图像处理的局限性^[8],特别是激光扫描仪^[9]、Kinect 传感器^[10]或立体相机等设备被用于获取 3D 道路数据。这类方法通过拟合道路表面的平面或二次曲面模型检测表面不平的坑洼。例如,Zhang 等^[11]使用无人机搭载的成像系统对未铺砌道路表面的坑洼进行了 3D 测量,而 Li 等^[12]则利用立体视觉和平面拟合技术检测道路坑洼。这些研究表明,3D 点云技术在提供精确的几何信息方面具有显著优势。然而,尽管 3D 点云技术在精确度上有所提升,但其高成本和设备的复杂性限制了它在实际中的广泛应用。

近年来,深度学习技术在坑洼道路检测领域展现出了巨大的潜力,包括图像分类、目标检测和语义分割等方法。图像分类技术虽然在识别图像中的主要对象方面表现出色,但通常不提供对象在图像中的具体位置信息,这对于坑洼的道路检测任务来说不能精确定位。而语义分割技术能够精确地识别并定位图像中的每个像素,但通常需要更多的计算资源,并且在处理速度上不如目标检测方法快,限制了无人车行驶所需的快速响应。考虑到道路坑洼检测的实际需求,以及目标检测方法在准确性、效率和实用性方面的优势,研究者们更倾向于采用目标检测技术来解决这一问题。这种方法不仅能够满足对坑洼进行快速识别和定位的需求,还能够在不同的环境条件下保持较高的鲁棒性。例如,Girshick 等^[13]提出的 R-CNN 系列算法,这是一种基于区域的卷积神经网络,它通过选择性搜索提取候选区域,然后利用 CNN 对这些区域进行特征提取和分类。R-CNN 虽然在准确性上取得了突破,但其检测速度较慢,因为它需要对每个候选区域单独进行特征提取和分类。为了解决速度问题,Redmon 等^[14]提出了 YOLO 算法,这是一种单阶段

检测算法,它将目标检测任务作为一个回归问题来解决,直接从图像像素到边界框坐标和类别概率。YOLO 算法的提出极大地提高了目标检测的速度,实现了接近实时的检测性能。然而,尽管 YOLO 算法在速度上具有优势,但它在小目标检测和准确性上仍有不足。为了解决这些问题,后续的研究者们对 YOLO 算法进行了多次迭代和改进,相继推出了 YOLOv2、YOLOv3、YOLOv4^[15] 和 YOLOv5 等版本。每个新版本都在不同程度上提高了模型的准确性、速度和鲁棒性。Wang 等^[16]提出了 YOLOv7,它在之前版本的基础上进行了进一步的优化和改进,在保持高速度的同时,提高了模型的准确性。然而,针对非结构化道路的坑洼检测,这些目标检测算法面对道路坑洼的多样性和复杂性通常难以有效适应,导致道路坑洼检测泛化能力和准确性太低。在实际应用中,这些方法容易导致漏检和误检的错误,对道路状况识别和评估的效率和质量造成影响。为此,许多研究者针对此问题展开研究。例如,王哲兴等^[17]提出了一种基于 YOLOv5 的改进的路面坑洼检测算法,通过引入一个概念简单、功能强大但非常新颖的注意力机制(BiFPN),并替换适合的激活函数与损失函数,使改进的算法与原模型相比准确率提升了 7.2%,召回率提高了 5.5%,平均准确率提升了 2.1%。高敏等^[18]提出了一种基于 YOLOv7-CA-BiFPN 的路面缺陷检测算法,通过引入 CA 注意力机制,采用 BiFPN 双向特征金字塔网络,将损失函数 SIoU 替换 CIOU,使改进之后的算法在坑洼数据集的平均精度均值和精确率相比于原本的 YOLOv7 版本提高了 6.18% 和 1.96%。

综上,将研究基于 YOLOv7 的坑洼道路检测,针对复杂场景下不同大小的不规则道路坑洼出现漏检的情况对 YOLOv7 进行以下改进:首先是引入增强的分层多尺度特征融合模块(enhanced hierarchical multi-scale fusion, EHMSF)对 SPPCSPC 模块(spatial pyramid pooling cross stage partial convolutions, SPPCSPC)进行改进,其次将 ECA 注意力机制模块(Efficient Channel Attention, ECA)加入到 EHMSF 模块前和 3 个检测头前,最后将 YOLOv7 前 4 层的标准卷积替换为深度可分离卷积。

1 YOLOv7 网络概述

YOLOv7 作为 YOLO 系列的最新成员,继承并优化了前代模型的核心思想,即在一个单一的网络中同时预测多个边界框和类别概率,无需区域建议或候选区域生成,从而实现快速且准确的目标检测。YOLOv7 网络结构如图 1 所示。其网络结构由几个关键部分组成:一个强大的骨干网络用于特征提取,一个高效的颈部网络用于特征融合,以及多个检测头用于在不同尺度上预测目标。骨干网络能够从输入图像中提取丰富的特征表示。颈部网络则负责将这些特征进行有效融合,增强特征的空间和尺度一致性。检测头则利用这些融合后的特征来预测目标的类别和位置。

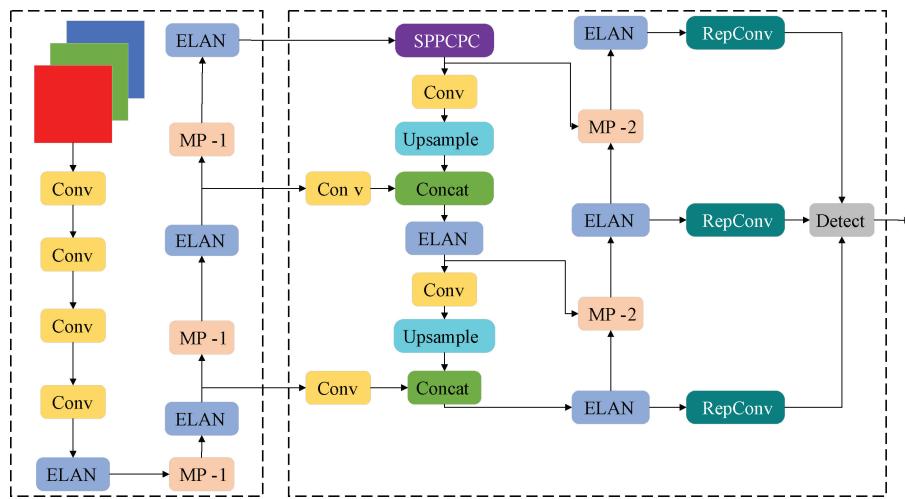


图 1 YOLOv7 网络结构

Fig. 1 YOLOv7 network structure

2 YOLOv7 改进方法

2.1 特征融合网络的改进

传统的 SPPCSPC 模块虽然通过结合空间金字塔池化和跨阶段部分网络的概念,提高了模型对多尺度特征的表达能力。然而,其在处理具有高度复杂性和多样性背景的目标时,仍显示出一定的局限性。例如,道路材质的不同、光照条件的变化以及周围环境的干扰等因素,使得坑洼道路的特征在轮廓、纹理和形态上变得复杂多变。此外,传统模块在捕捉不同尺度的特征时,从大的路面结构到小的裂缝和坑洼,往往检测精度受限。因此,通过引入 EHMSF 模块对 SPPCSPC 模块进行改进。引入的 EHMSF 网络结构如图 2 所示。不仅在特征融合过程中保留了原始输入特征图,而且在第一次融合后,进一步与经过额外处理的特征图进行拼接,从而增强了特征的表达力和模型的判别能力。此外,EHMSF 模块通过采用不同尺寸的池化层 ($3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11$),其跨度由 4 变为 2,实现了更细粒化的多尺度特征捕获,提供了更细致的特征层次。

2.2 注意力机制的引入

在 YOLOv7 结构中,SPPCSPC 模块的作用是通过不同尺度的池化操作来聚合多尺度特征,而检测头则直接在多尺度特征图上进行目标检测和定位。由于缺乏通道间的依赖关系,YOLOv7 在复杂场景中无法充分关注对检测任务有利的特征通道,导致特征选择不够精确,从而影响检测精度。

为了解决这一问题,提出了一种改进方法:将 ECA 模块加入到 SPPCSPC 模块前和 3 个检测头前。ECA 是一种高效的轻量级通道注意力机制^[19],旨在提升神经网络的特征表达能力。其原理是通过一维卷积在通道维度上实现局部的跨通道交互,以此捕捉通道间的依赖关系,同时避

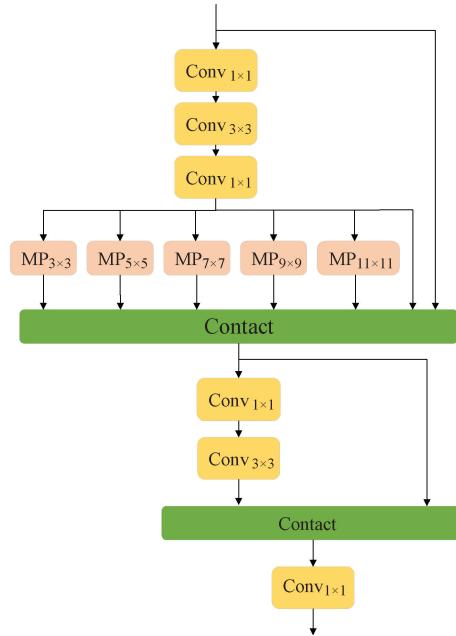


图 2 EHMSF 模块结构

Fig. 2 Structure of EHMSF module

免降维操作带来的计算量。引入的 ECA 结构如图 3 所示。首先对每个通道的特征图进行全局池化以提取全局特征,接着通过一维卷积捕捉通道间的局部依赖关系,最后通过 sigmoid 激活函数生成自适应权重,从而对特征图进行加权。在 SPPCSPC 模块前引入 ECA 模块后,YOLOv7 在多尺度特征聚合过程中可以更精准地关注关键通道信息,从而提升特征的区分能力和表达效果。在检测头前加入 ECA 模块,进一步增强了检测阶段的特征表达,使模型在不同尺度的目标检测任务中具备更高的准确性和鲁棒性。通过在这些关键位置引入 ECA,YOLOv7 在计算量几乎不变的前提下实现整体性能的显著提升。

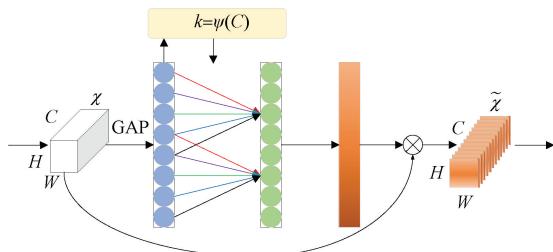


图 3 ECA 模块结构

Fig. 3 Structure of ECA module

2.3 轻量化处理

在无人驾驶系统中,实时检测道路坑洼对于保证行车安全至关重要。尤其是在非结构化道路环境中,坑洼、裂缝和其他障碍物常常没有明确的标记,且可能随时出现在不同的位置,增加了检测的复杂性。与结构化道路不同,非结构化道路的复杂性和变化性对检测模型提出了更高的要求。传统的卷积在图像特征提取方面虽然表现出色,但随着网络深度的增加,特别是在处理复杂道路场景时,其计算复杂度和内存需求也随之增加。这会导致模型的实时性受到限制,影响无人驾驶系统在动态和复杂环境中的性能。

为此,提出将 YOLOv7 前 4 层的标准卷积(图 4)替换为深度可分离卷积^[20](图 5)。深度可分离卷积通过将传统卷积操作分解为两个步骤:首先是深度卷积(图 5(a)),仅对每个输入通道进行卷积操作;接着通过逐点卷积(图 5(b))聚合不同通道的信息。

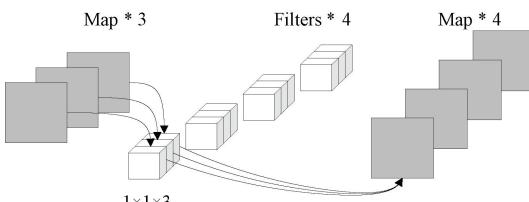


图 4 标准卷积模块结构

Fig. 4 Structure of standard convolution module

假设输入特征图的尺寸为 $H \times W \times C_{in}$ (其中 H 和 W 为特征图的高度和宽度, C_{in} 为输入通道数),输出通道数为 C_{out} ,则对于 $k \times k$ 的标准卷积,参数量为:

$$P_{\text{standard}} = k \times k \times C_{in} \times C_{out} + C_{out} \quad (1)$$

对于深度可分离卷积,参数量为:

$$P_{\text{separable}} = P_{\text{depthwise}} + P_{\text{pointwise}} = k \times k \times C_{in} + C_{in} \times C_{out} \quad (2)$$

从上述式(1)和(2)可以看出,深度可分离卷积的总参数量相较于标准卷积的总参数量极大地减少。在 YOLOv7 中,前 4 层的卷积主要负责提取图像的低级别特征,且这些层的计算量较大,使用深度可分离卷积替代传统卷积,不仅能大幅降低计算开销,还能保持良好的特征提取效果。

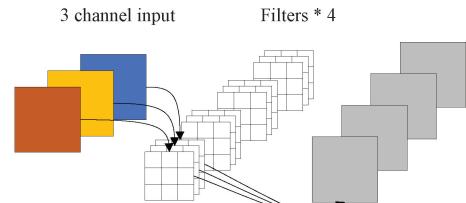
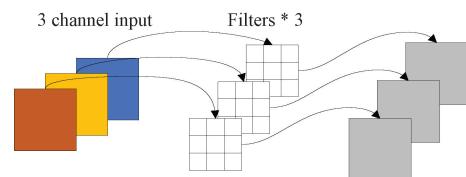
(a) 深度卷积模块结构
(a) Structure of the deep convolution module(b) 逐点卷积模块结构
(b) Structure of point-by-point convolution module

图 5 卷积模块结构

Fig. 5 Structure of convolution module

3 实验及结果分析

3.1 实验准备

实验中验证改进结构有效性和与不同模型的对比采用自制的数据集,该数据集包含 665 张图像的坑洼道路数据集,其中覆盖了乡村土路、水泥路、沥青路面等多种道路场景,并考虑了不同的光照条件和天气情况(如晴天、阴天、雨天等),以确保数据的多样性。部分数据集如图所示。为确保模型训练、验证和测试的效果,按照 7:2:1 的比例划分为训练集、验证集和测试集,其中 465 张图片用于训练,133 张用于验证,67 张用于测试。另外为了提升模型的泛化能力,结合了训练过程中的随机数据增强技术来提升模型的性能,其中包括旋转、裁剪、色彩度变换等,原图如图 6 所示,经过旋转、裁剪、色彩度变换数据增强的坑洼道路图像如图 7 所示。



图 6 坑洼道路原图

Fig. 6 Pothole road original diagram

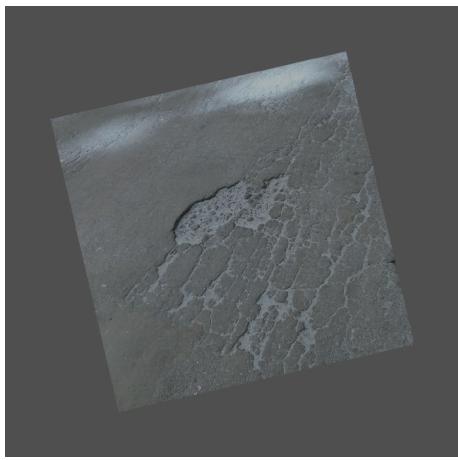


图 7 坑洼道路旋转、裁剪、色彩度变换图

Fig. 7 Rotation, cutting, and color transformation diagram of pothole road

改进后模型进行迁移学习使用坑洼道路公开数据集,该数据集的训练集包含 11 068 张图片、验证集包含 1 808 张图片、测试集包含 891 张图片。其中训练集的图片如图 8 所示。该数据集与自制数据集相似,为模型迁移学习提供良好的基础,能够使模型更快地适应自制数据集。



图 8 坑洼道路公开数据集训练集原图

Fig. 8 Original image of the training set of the pothole road public dataset

3.2 评价指标

为了全面评估模型在坑洼道路检测任务中的表现,选取精确率(P)、召回率(R)、平均精度均值(MAP)、参数量(Pa)和每秒帧数(FPS)作为评估指标。

P 表示模型在所有预测为正类的样本中,实际为正类的比例,其定义如下:

$$P = \frac{TP}{TP + FP} \quad (3)$$

其中,TP 表示正确检测出的坑洼区域数,FP 表示错误检测为坑洼的非坑洼区域数。P 越高,说明模型在检测时误检率越低。

R 表示模型在所有实际为正类的样本中,成功检测出的比例,其定义如下:

$$R = \frac{TP}{TP + FN} \quad (4)$$

其中,FN 表示未能检测出的实际坑洼区域数。R 越高,说明模型漏检率越低。

MAP 是衡量目标检测任务整体性能的重要指标,是各类别的 P 的平均值。定义如下:

$$MAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

其中,N 是类别数,AP 是 P-R 曲线下的面积。

Pa 表示模型中可训练参数的总数量,用于衡量模型的复杂度。参数量越少,通常意味着模型占用的内存和计算资源更少。FPS 用于衡量模型的推理速度,即每秒钟处理的图像帧数。FPS 越高,说明模型的推理效率越高。

3.3 网络训练

1) 验证改进结构的有效性

为了系统地验证每个改进模块和整体的效果,在基于原始 YOLOv7 模型的基础上,依次改进每个模块并进行测试,使用 P、R、MAP、Pa、以及 FPS 五个指标评估模型性能。其中改进的 YOLOv7 与 YOLOv7 的 P、R、MAP 的对比如图 9(a)、(b)、(c) 所示。将其数值取平均数作为最终结果如表 1 所示。可以看出,引入 EHMSF 模块对 SPPCSPC 模块进行改进和引入 ECA 注意力机制后,虽然参数量有所增加,检测速度小幅度减少,但是其 P、R、MAP 均有大幅度提升,其中引入 EHMSF 模块对 SPPCSPC 模块进行改进后,P、R、MAP 分别提升 3.56%、3.71%、6.01%;引入 ECA 注意力机制后,P、R、MAP 分别提升 5.3%、4.03%、6.23%。此外,用深度可分离卷积替换普通卷积后检测速度得到提高。最终将其融合在一起的改进后的 YOLOv7 在检测速度小幅度减少的情况下,P、R、MAP 分别提升 5.47%、4.42%、6.65%,验证了各改进模块在提升检测性能方面的有效性。

通过对改进前后模型的可视化分析,如图 10 和 11 所示,图 10 为原始的检测结果图,图 11 为改进后的检测结果图,可以发现,原始 YOLOv7 模型在检测坑洼时存在一定的漏检现象。此外,原模型还对于不同尺寸的坑洼识别结果不够精细化。引入 EHMSF 模块及 ECA 注意力机制后,模型在检测性能上得到了显著提升,能够更全面地检测出原本容易漏检的坑洼区域。同时,改进后的模型实现更细粒度的检测。

2) 不同模型的对比

为了确保所提出的改进在不同模型之间的优势,选取了常用的目标检测网络 YOLOv7x、YOLOv7-d6、YOLOv5x、YOLOv5m^[21] 作为对照组,并使用 P、R、MAP、Pa 以及 FPS 五个指标评估模型性能。其中 P、R、MAP 在其训练过程中的结果如图 12(a)~(c) 所示,将其取平均数

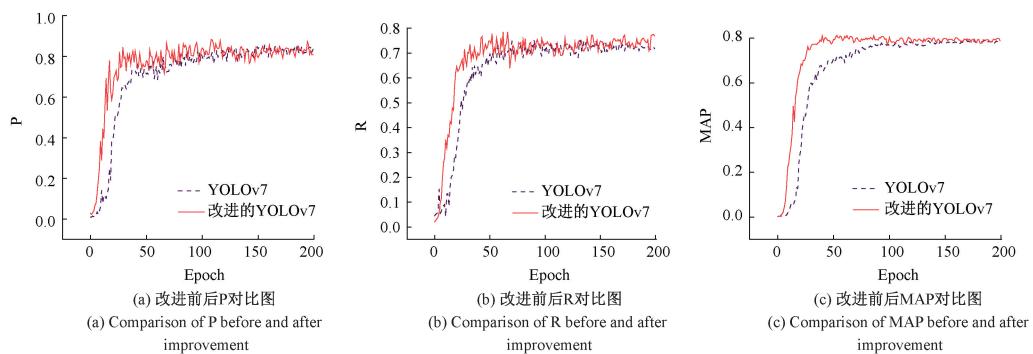


图 9 改进的 YOLOv7 与 YOLOv7 对比图

Fig. 9 Improved YOLOv7 compared to YOLOv7 chart

表 1 不同 YOLOv7 改进方法的模型性能

Table 1 Model performance of different improved modules

模型	P/%	R/%	MAP/%	Pa/ 10^7	FPS
YOLOv7	70.72	63.61	66.78	3.72	36.92
YOLOv7+EHMSF	74.28	67.32	72.79	4.09	35.03
YOLOv7+ECA	76.02	67.64	73.01	3.73	36.08
YOLOv7+DSC	68.36	57.05	59.92	3.71	37.65
改进的 YOLOv7	76.19	68.03	73.43	4.01	35.28



图 10 改进前检测结果图

Fig. 10 Plot of detection results before improvement



图 11 改进后检测结果图

Fig. 11 Plot of improved detection results

作为最终结果列于表 2, 不同网络在数据集的对比如表所示, 可以看出, 改进后的 YOLOv7 的 P、R、MAP 比 YOLOv7x 分别提升 35.57%、35.33%、43.61%, 比 YOLOv7-d6 分别提升 40.71%、42.33%、51.33%, 比 YOLOv5x 分别提升 16.77%、15.84%、44.12%, 比 YOLOv5m 分别提升 15.49%、15.42%、18.1%。这些实验结果充分证明了改进后的 YOLOv7 模型在各项性能指标上均优于其他主流目标检测网络, 展示了更为显著的检测效果和鲁棒性。

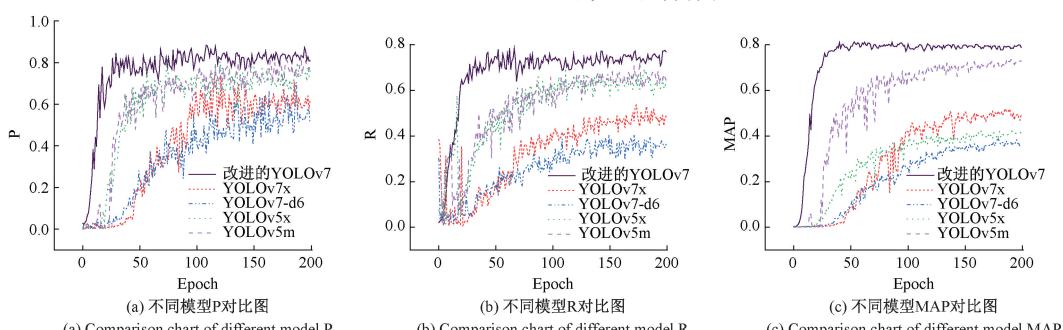


图 12 改进的 YOLOv7 和常用目标检测网络的 P、R、MAP 对比图

Fig. 12 Comparison of P, R, and MAP between improved YOLOv7 and commonly used object detection networks

表 2 改进的 YOLOv7 和常用目标检测网络的性能对比

Table 2 Performance comparison between improved YOLOv7 and commonly used object detection networks

模型	P/%	R/%	MAP/%	$Pa/10^7$	FPS
改进的 YOLOv7	76.19	68.03	73.43	4.01	35.28
YOLOv7x	40.62	32.70	29.82	7.08	24.98
YOLOv7-d6	35.48	25.70	22.10	0.60	127.03
YOLOv5x	59.42	52.19	29.31	8.62	22.87
YOLOv5m	60.70	52.61	55.33	2.08	68.36

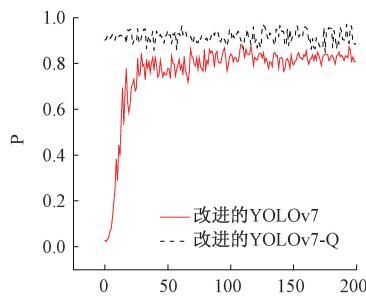
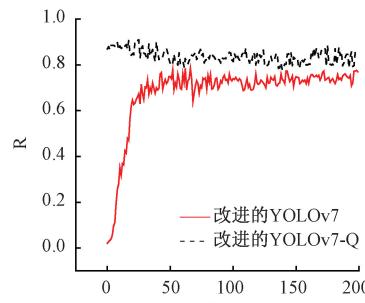
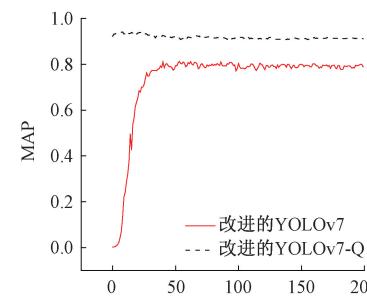
(a) 改进的 YOLOv7 迁移学习的P对比图
(a) P comparison chart of improved YOLOv7 transfer learning(b) 改进的 YOLOv7 迁移学习的R对比图
(b) R comparison chart of improved YOLOv7 transfer learning(c) 改进的 YOLOv7 迁移学习的MAP对比图
(c) MAP comparison chart of improved YOLOv7 transfer learning

图 13 改进的 YOLOv7 迁移学习的 P、R、MAP 对比图

Fig. 13 Comparison of P, R, and MAP of improved YOLOv7 transfer learning

表 3 改进的 YOLOv7 迁移学习的性能对比

Table 3 Performance comparison of improved YOLOv7 transfer learning

模型	P	R	MAP	%
改进的 YOLOv7	76.19	68.03	73.43	
改进的 YOLOv7-Q	91.56	83.74	91.74	

4 结论

本文针对基于改进 YOLOv7 的非结构化道路坑洼检测进行了深入研究, 主要结论如下:

设计优化了 YOLOv7 目标检测模型, 通过引入 EHMSF 模块、ECA 注意力机制以及深度可分离卷积, 显著提升了模型的多尺度特征提取能力和检测性能。实验结果表明, 改进后的模型在自制数据集上的精确率、召回率和平均精度分别提高了 5.47%、4.42% 和 6.65%, 同时在保持 35.28FPS 检测速度的前提下降低了计算复杂度。

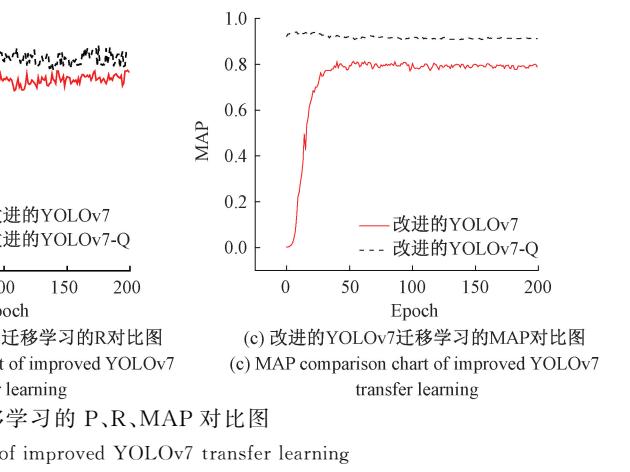
通过与 YOLOv7x、YOLOv7-d6、YOLOv5x 和 YOLOv5m 等主流模型对比, 实验结果表明, 改进的 YOLOv7 在检测精度和效率方面更具优势。

改进的 YOLOv7 在公开数据集预训练后迁移学习使模型 P、R、MAP 分别提升 15.37%、15.71% 和 18.31%。

本文提出的改进 YOLOv7 模型为非结构化道路坑洼

3) 迁移学习的对比

为了解决自制数据集数据量较小影响模型准确率的问题, 在公开数据集上预训练模型, 并将其权重迁移到自有数据集上进行迁移学习。并使用 P、R、MAP 三个指标评估模型性能。其中 P、R、MAP 在其训练过程中的结果如图 13(a)~(c) 所示, 将其取平均数作为最终结果列于表 3, 可以看出, 改进的 YOLOv7 经迁移学习后(改进的 YOLOv7-Q), P、R、MAP 分别提升 15.37%、15.71%、18.31%。实验结果证明了改进后的 YOLOv7 模型经迁移学习提升了模型的精度和泛化能力。



检测提供了一种高效、准确的解决方案, 在无人驾驶系统和智能交通领域具有重要的理论意义和实用应用价值。

参考文献

- [1] 曹江华. 复杂背景下非结构化道路可行驶区域检测研究[D]. 杭州: 浙江科技学院, 2020.
- [2] CAO J H. Research on detectable region of unstructured roads under complex backgrounds[D]. Hangzhou: Zhejiang University of Science and Technology, 2020.
- [3] 程森豪, 张志峰, 马宁. 路面裂缝图像处理技术综述[J]. 南方农机, 2024, 55(10): 11-15, 20.
- [4] CHENG S H, ZHANG ZH F, MA N. A review of pavement crack image processing technology [J]. South Agricultural Machinery, 2024, 55 (10): 11-15, 20.
- [5] 王青宁. 基于图像处理的路面病害检测方法研究[D]. 南京: 南京信息工程大学, 2022.
- [6] WANG Q N. Research on pavement disease detection methods based on image processing [D]. Nanjing: Nanjing University of Information Science & Technology, 2022.
- [7] KOCH C, BRILAKIS I. Pothole detection in asphalt pavement images [J]. Advanced Engineering Informatics, 2011, 25(3): 507-515.

- [5] RYU S K, KIM T, KIM Y R. Feature-based pothole detection in two-dimensional images [J]. Transportation Research Record: Journal of the Transportation Research Board, 2015, 2528(1):9-17.
- [6] JAHANSHAHI R M, JAZIZADEH F, MASRI F S, et al. Unsupervised approach for autonomous pavement-defect detection and quantification using an inexpensive depth sensor [J]. Journal of Computing in Civil Engineering, 2013, 27(6):743-754.
- [7] 贾建鑫,孙海彬,蒋长辉,等.多源遥感数据的道路提取技术研究现状及展望[J].光学精密工程,2021,29(2):13.
JIA J X, SUN H B, JIANG C H H, et al. Research status and prospect of road extraction technology based on multi-source remote sensing data[J]. Optics and Precision Engineering, 2021, 29(2): 13.
- [8] FAN R, AI X, DAHNOUN N. Road surface 3D reconstruction based on dense subpixel disparity map estimation [J]. IEEE Transactions on Image Processing, 2018, 27:1-1.
- [9] 胡宏宇,唐明弘,高菲,等.基于点云反射特性的前方道路附着系数估计方法研究[J].汽车工程,2024,46(10):1842-1852.
HU H Y, TANG M H, GAO F, et al. Research on the estimation method of the road adhesion coefficient ahead based on the reflection characteristics of point clouds[J]. Automotive Engineering, 2024, 46 (10): 1842-1852.
- [10] BANERJEE T, YEFIMOVA M, KELLER J M, et al. Exploratory analysis of older adults' sedentary behavior in the primary living area using kinect depth data[J]. Journal of Ambient Intelligence & Smart Environments, 2017, 9(2):163-179.
- [11] ZHANG C, ELAKSHER A. An unmanned aerial vehicle-based imaging system for 3D measurement of unpaved road surface distresses[J]. Computer-Aided Civil and Infrastructure Engineering, 2012, 27 (2): 118-129.
- [12] LI Y, PAPACHRISTOU C, WEYER D. Road pothole detection system based on stereo vision[C]. NAECON 2018-IEEE National Aerospace and Electronics Conference. IEEE, 2018: 292-297.
- [13] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2014:580-587,DOI:10.1109/CVPR.2014.81.
- [14] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [16] 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]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [17] 王哲兴,李军,谭倩.基于改进YOLOv5的路面坑洼检测算法研究[J].激光与红外,2024,54(5):814-823.
WANG ZH X, LI J, TAN Q. Research on road pothole detection algorithm based on improved YOLOv5 [J]. Laser & Infrared, 2024, 54 (5): 814-823.
- [18] 高敏,李元.基于YOLOv7-CA-BiFPN的路面缺陷检测[J].计算机测量与控制,2024,32(9):9-14,43.
GAO M, LI Y. Road surface defect detection based on YOLOv7-CA-BiFPN[J]. Computer Measurement & Control, 2024, 32(9): 9-14,43.
- [19] 陈晓杰,王亮,赵美玲,等.基于ECA-YOLOv5s的煤矿带式输送机异物检测网络模型[J].采矿技术,2024, 24(4):316-324.
CHEN X J, WANG L, ZHAO M L, et al. Foreign object detection network model for coal mine belt conveyors based on ECA-YOLOv5s [J]. Mining Technology, 2024, 24(4): 316-324.
- [20] 刘文钊,张丹.基于机器视觉的轻量化钢材表面缺陷检测模型[J].计算技术与自动化,2024, 43(3):43-49.
LIU W ZH, ZHANG D. A surface defect detection model for lightweight steel based on machine vision[J]. Computing Technology and Automation, 2024, 43(3): 43-49.
- [21] 李玥,马世典,黄宇轩.基于改进YOLOv5m的室内停车位检测[J].软件导刊,2024,23(4):157-163.
LI Y, MA SH D, HUANG Y X. Indoor parking space detection based on improved YOLOv5m [J]. Journal of Software Guide, 2019,23(4):157-163.

作者简介

曲雪莲,硕士,主要研究方向为计算机视觉。

E-mail: jyd000513@163.com

周福强(通信作者),博士,研究员,主要研究方向为智能轮胎、机器视觉。

E-mail: fuqiangzhou@126.com