

基于深度学习的无人驾驶汽车道路坑洞检测技术

周家强, 胡宇航, 石竞奇, 宋森楠*, 阮良军

宁波工程学院机械与汽车工程学院, 浙江 宁波

收稿日期: 2024年10月30日; 录用日期: 2024年11月27日; 发布日期: 2024年12月5日

摘要

道路坑洞威胁着汽车的驾驶安全, 针对无人驾驶汽车, 进行可靠的坑洞检测尤为重要。在所有的检测方法中, 基于深度学习网络的图像识别算法具有更高的精度和更快的检测速度。因此, 本文旨在提供基于YOLOv5的高精度坑洞检测方法。具体来说, 首先在中国城乡道路上采集了1000张图像, 通过网络搜索引擎获得了1500张图片。使用YOLOv5s模型对获得的数据集进行训练, 同时, 对原有的模型进行了优化, 增加SE注意力机制和BiFPN特征融合机制, 以获得更好的精度和泛化性。检测结果表明, 优化后的模型检测精度由81.1%提高到95.0%; mAP0.5由89.1%提高到92.2%; mAP0.5:0.95由48.2%提高到49.5%; 检测速度基本与原模型持平, 可满足实时检测要求。因此, 本文获得了一种可实时且性能更优的道路坑洞检测方法, 可应用于无人驾驶汽车安全系统。

关键词

深度学习, YOLOv5, 注意力机制, 特征融合机制

Road Pothole Detection for Autonomous Vehicles Based on Deep Learning

Jiaqiang Zhou, Yuhang Hu, Jingqi Shi, Sennan Song*, Liangjun Ruan

College of Mechanical and Automotive Engineering, Ningbo University of Technology, Ningbo Zhejiang

Received: Oct. 30th, 2024; accepted: Nov. 27th, 2024; published: Dec. 5th, 2024

Abstract

Road potholes pose a threat to the driving safety of cars, especially for autonomous vehicles, and

*通讯作者。

文章引用: 周家强, 胡宇航, 石竞奇, 宋森楠, 阮良军. 基于深度学习的无人驾驶汽车道路坑洞检测技术[J]. 计算机科学与应用, 2024, 14(12): 29-35. DOI: 10.12677/csa.2024.1412237

reliable pothole detection is particularly important. Among all detection methods, image recognition based on deep learning networks has higher accuracy and faster detection speed. Therefore, this article aims to provide a high-precision pit detection method based on YOLOv5. Specifically, 1000 images were collected on urban and rural roads in China, and 1500 images were obtained through online search engines. Train the obtained dataset using the YOLOv5s model. Optimize the activation function, add attention mechanism and BiFPN feature fusion mechanism to achieve better accuracy and generalization. The results show that the accuracy of the optimized model has increased from 81.1% to 95.0%; mAP0.5 increased from 89.1% to 92.2%; mAP0.5:0.95 increased from 48.2% to 49.5%. The detection speed is basically the same as the original model, which can meet the requirements of real-time detection. Therefore, this article presents a real-time and high-performance method for detection, which can be applied to the safety system of autonomous vehicles.

Keywords

Deep Learning, YOLOv5, Attention Mechanism, Feature Fusion Mechanism

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

无人驾驶汽车技术发展迅速,但无人驾驶汽车环境感知能力还有待提高。目前,对于汽车、行人、道路残留物等凸出型障碍物的检测相对成熟,但对道路凹陷型检测的研究略有不足。道路坑洞会影响乘坐舒适性,还会破坏轮胎、悬架和车轴,甚至导致故障抛锚。在中国,大量道路使用时间长,使用强度高,导致道路坑洞增加,而且在降雨[1]后也会容易产生坑洞。在传统汽车中,驾驶员可以用肉眼观察坑洞,而无人驾驶汽车必须采用先进的传感技术[2]来检测坑洞。

目前最广泛使用的检测方法是图像识别。一般来说,图像会受到光线、环境、形状和障碍物的影响,因此,目标检测任务一直都是极具挑战性的。目前,现有的坑洞检测技术主要有图像识别和 3D 雷达扫描等,激光扫描检测精度高,能精准判别前方坑洞,但是存在检测距离短,检测时间长等问题,无法满足行车过程中实时检测的要求,而传统的图像识别方法又存在检测精度低,容易漏检和误检的问题。因此,本文拟采集大量道路坑洞图片作为数据集,同时采用基于 YOLOv5s 深度学习算法的目标检测技术,对该算法进行优化。

2. 相关工作

2.1. 坑洞检测工作

在过去的几年里,人们提出了一些坑洞检测方法。She [3]提出了一种利用三维线激光数据全面精确测量坑洞特性的新方法,结果表明,坑洞特性测量的相对误差在 3.66%至 4.78%之间;Aparna [4]提出了一种基于卷积神经网络的热成像方法,在夜间和多雾天气条件下也有效,作者声称精度达到 97.08%。上述方法具有较高的检测精度,但无法实现快速实时的多目标检测。Huidrom [5]提出了一种基于实时机器学习的方法,实现了一种用于自动检测和评估现实视频剪辑中的坑洼、裂缝和补丁的方法;Egaji [6]使用 RFT(随机森林树)应用了一个 2 秒的非重叠移动窗口进行特征提取,超参数调整后的准确率、精确度、召回率分别为 0.9444、1.0000、0.8889,但是检测速度较低。

2.2. 深度学习网络

Puliti [7]提出了一种基于 YOLOv5 的目标检测方法,可以自动识别树木并根据雪的损伤对其进行分类,达到了 76%的准确率和 78%的召回率,该研究适用于无人机图像采集。Li [8]介绍了基于光照校正和补偿的图像增强方法,并使用 YOLOv5 对模型进行检测,提高了应对外部光照变化的能力。He [9]简化了 YOLOv5 的网络结构并将其应用于野火检测模型,增加了注意力机制,改进的野火检测算法的平均准确率为 71.5%,召回率为 66.2%。Jubayer [10]为了识别生长在各种食物表面上的不同霉菌,使用 YOLOv5 算法对数据集进行训练,采用 BiFPN 特征提取网络,精确度、召回率和平均精确度(AP)分别为 98.10%、100%和 99.60%。Cao [11]提出了基于 YOLOv5 的重载铁路钢轨扣件检测方法,该方法修改了锚具尺寸,以提高对扣件小目标的关注度,结果表明改进后的 YOLOv5 具有良好的性能和良好的应用前景。上述文献中, YOLOv5 算法的优化方向主要是图像增强、添加注意力机制、改善特征提取机制等,为本文的优化方向提供了思路。

3. 模型设计

3.1. 数据集

数据集中共有 2500 幅图像,其中 1000 幅是通过城市和农村道路的实地拍摄收集的,另外 1500 幅是通过网络搜索引擎获得的,所有图像都包括不同的环境,如照明、天气和路面(水泥、沥青和土路),还包括不同大小和形状的坑洞。在原始图像的基础上,我们通过旋转、缩放、对称、颜色去除甚至虚化来扩展数据集。此外,众所周知,同一物体在不同距离处呈现出不同的形状,因此,本文拍摄了不同距离处的坑洞照片,如图 1 所示。所有这些工作都旨在增加数据的多样性和检测的泛化性。所有标注都是通过 Labelimg 标注工具手动完成的,然后自动将数据集划分为训练集和验证集。至此,数据集的准备工作已经完成。




Figure 1. Pothole shapes in different distance
图 1. 不同距离的坑洞形状

3.2. YOLOv5 识别算法

在本文中, YOLOv5 被提出用于凹坑检测,其网络框架融合了 Mosaic 数据增强和自适应锚框方法,提高了小目标检测能力。另外,在 Backbone 和 Neck 部分部署了 CSP 结构,以增强网络特征的融合能力。

3.3. 评估指标

以下是关于 YOLOv5 的几个评估指标,真阳性(TP)表示被正确识别为阳性采样的数量,假阳性(FP)表示被错误识别为阳性的阴性样本数量,假阴性(FN)表示被不正确识别为阴性采样的数量、精确度(P)、

召回率(R)、平均精确度(AP)、平均准确度(mAP)表示检测精确度, 定义如下公式:

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$P = \frac{TP}{TP + FN} \quad (2)$$

$$AP = \int_0^1 P dR \quad (3)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{N} \quad (4)$$

4. 优化

4.1. 注意力机制

在图像处理过程中, 人类选择性地注意力集中在视觉空间的一部分以获取信息, 将计算资源集中在图像的一部分上以节省“带宽”, 这大大降低了任务的复杂性, 因为需要处理的像素更少。因此, 我们将注意力机制嵌入到机器学习模型中, 随着深度学习能力的增强, 特征提取将更加具体。在本文中, 引入了 SE 注意力机制[11], 该机制为每个特征图提供不同的权重。本文采用的 SE 注意力机制为每个特征图提供不同的权重, 并专注于更有用的图。SE 的过程分为两个步骤: 挤压和激励:

- 1) 挤压: 通过对特征图进行全局池化, 获得当前特征图的全局压缩特征;
- 2) 激励: 通过两层全连接瓶颈结构获得特征图中每个通道的权重, 将加权后的特征图作为下一层网络的输入。

SE 构建块的结构如图 2 所示:




Figure 2. The structure of the SE building block
图 2. SE 构建块的结构

4.2. BiFPN 特征融合机制




Figure 3. BiFPN feature network
图 3. BiFPN 网络结构

在融合不同分辨率的特征时,传统的方法是将它们调整到相同的分辨率并融合,但不同的特征具有不同的输入分辨率,对输出特征的贡献也不同,因此提出了一种加权双向特征金字塔网络(BiFPN),如图3所示,该网络建议为每个输入添加额外的权重,并使每个输入特征的重要性由网络学习得到。

BiFPN 构建了一个自上而下和自下而上的双向通道。当在不同尺度之间融合来自 Backbone 网络不同尺度的信息时,使用相同的上采样和下采样特征分辨率尺度,并在相同特征的原始输入和输出节点之间添加水平连接,融合更多特征。

4.3. 结果

将应用了 SE 注意力机制和 BiFPN 特征融合机制的优化 YOLOv5s 模型标记为 YOLOv5s-opt,将原始 YOLOv5s 标记为 YOLOv5s-ori,我们使用已建立的训练参数对两个模型进行训练,并绘制评估指标图进行比较,如图4所示。




Figure 4. Comparison of YOLOv5s-opt and YOLOv5s-ori

图 4. YOLOv5s-opt 和 YOLOv5s-ori 对比

Table 1. Comparison of YOLOv5s-opt and YOLOv5s-ori

表 1. YOLOv5s-opt 和 YOLOv5s-ori 对比

	YOLOv5s-ori	YOLOv5s-opt
P	81.1%	95.0%
R	90.9%	90.5%
mAP0.5	89.1%	92.2%

续表

mAP0.5:0.95	48.2%	49.5%
Detection time (t)	73.0 ms	75.3 ms
FPS	13.7	13.3

从表 1 可以看出, YOLOv5s opt 表现更好: 收敛速度更快; 精度由 81.1% 提高到 95.0%; mAP0.5 由 89.1% 提高到 92.2%; mAP0.5:0.95 由 48.2% 提高到 49.5%, 此三项为判断检测精度的核心指标, 即优化后的算法具备了更高的检测精度。根据表 1 所示, 优化前后, FPS 分别为 13.7 和 13.3, 检测速度无明显放缓, 仍能满足实时检测要求, 这是由于上述优化措施并没有大幅增加 YOLOv5 原网络的复杂度。此外, 如图 5 所示, 优化前模型将路边树叶错误的识别为坑洞(蓝圈内), 而优化后模型成功地避免了此类错误, 降低了错检率, 这意味着模型的泛化能力和准确性也得到了提高。



Figure 5. Comparison of detection effect of YOLOv5s-ori and YOLOv5s-opt
图 5. YOLOv5s-ori 及 YOLOv5s-opt 检测效果对比

5. 结论

针对无人驾驶汽车的坑洞实时检测问题, 本文提出了一种基于深度学习网络的坑洞检测模型。首先, 建立了一个包含 2500 幅图像的数据集, 包括在中国城乡道路上通过实地拍摄收集的 1000 幅图像(包含不同距离拍摄的照片)和通过网络搜索引擎获得的 1500 幅图像。其次, 使用 YOLOv5s 模型对所获得的数据集进行训练。然后在 YOLOv5s 的基础上, 增加注意力机制和 BiFPN 特征融合机制。实验结果表明, 检测精度由 81.1% 提高到 95.0%; mAP0.5 由 89.1% 提高到 92.2%; mAP0.5:0.95 由 48.2% 提高到 49.5%; 而检测速度基本保持不变, 可满足实时检测要求; 同时错检率有所降低, 意味着模型的泛化能力和准确性也得到了提高。

本文获得了一种可同时满足实时性和高检测精度的坑洞检测方法, 为无人驾驶汽车实现路面坑洞检测提供了一种可行的方法。后续可继续进一步完善坑洞数据集, 提升模型的检测性能。

基金项目

浙江省大学生科技创新活动计划暨新苗人才计划项目(2024R428A005)。

参考文献

- [1] 张培元. 高速公路路面坑槽和裂缝的维修策略[J]. 交通建设, 2018(22): 246-247.
- [2] Lee, S., Le, T.H.M. and Kim, Y. (2023) Prediction and Detection of Potholes in Urban Roads: Machine Learning and Deep Learning Based Image Segmentation Approaches. *Developments in the Built Environment*, **13**, Article 100109. <https://doi.org/10.1016/j.dibe.2022.100109>

-
- [3] She, X., Hongwei, Z., Wang, Z. and Yan, J. (2021) Feasibility Study of Asphalt Pavement Pothole Properties Measurement Using 3D Line Laser Technology. *International Journal of Transportation Science and Technology*, **10**, 83-92. <https://doi.org/10.1016/j.ijtst.2020.07.004>
- [4] Bhatia, Y., Rai, R., Gupta, V., Aggarwal, N. and Akula, A. (2022) Convolutional Neural Networks Based Potholes Detection Using Thermal Imaging. *Journal of King Saud University—Computer and Information Sciences*, **34**, 578-588. <https://doi.org/10.1016/j.jksuci.2019.02.004>
- [5] Huidrom, L., Das, L.K. and Sud, S.K. (2013) Method for Automated Assessment of Potholes, Cracks and Patches from Road Surface Video Clips. *Procedia—Social and Behavioral Sciences*, **104**, 312-321. <https://doi.org/10.1016/j.sbspro.2013.11.124>
- [6] Egaji, O.A., Evans, G., Griffiths, M.G. and Islas, G. (2021) Real-Time Machine Learning-Based Approach for Pothole Detection. *Expert Systems with Applications*, **184**, Article 115562. <https://doi.org/10.1016/j.eswa.2021.115562>
- [7] Puliti, S. and Astrup, R. (2022) Automatic Detection of Snow Breakage at Single Tree Level Using YOLOv5 Applied to UAV Imagery. *International Journal of Applied Earth Observation and Geoinformation*, **112**, Article 102946. <https://doi.org/10.1016/j.jag.2022.102946>
- [8] Li, Y., Ni, M. and Lu, Y. (2022) Insulator Defect Detection for Power Grid Based on Light Correction Enhancement and YOLOv5 Model. *Energy Reports*, **8**, 807-814. <https://doi.org/10.1016/j.egyr.2022.08.027>
- [9] He, H., Zhang, Z., Jia, Q., Huang, L., Cheng, Y. and Chen, B. (2023) Wildfire Detection for Transmission Line Based on Improved Lightweight YOLO. *Energy Reports*, **9**, 512-520. <https://doi.org/10.1016/j.egyr.2022.10.435>
- [10] Jubayer, F., Soeb, J.A., Mojumder, A.N., Paul, M.K., Barua, P., Kayshar, S., *et al.* (2021) Detection of Mold on the Food Surface Using YOLOv5. *Current Research in Food Science*, **4**, 724-728. <https://doi.org/10.1016/j.crfs.2021.10.003>
- [11] 张德春, 李海涛, 李勋等. 基于 CBAM 和 BiFPN 改进 YOLOV5 的渔船目标检测[J]. 渔业现代化, 49(3): 71-80.