

基于深度学习的复杂路况下道路病害快速检测研究

周浩然

宁波正信检测科技有限公司 浙江 宁波 315200

摘要：随着城市化进程的加速和交通网络的日益复杂，城市道路的安全性和通畅性对于维持城市功能的高效运转变得至关重要。然而，由于自然侵蚀、材料老化以及重载车辆的频繁通行，道路表面往往会出现裂缝、坑洼等病害，这些不仅降低了道路的通行效率，更对交通安全构成了严重威胁。因此，对道路病害进行及时、准确的检测与评估显得尤为重要。本文围绕复杂路况下的道路病害快速检测问题，深入研究了基于深度学习的检测方法，旨在提高检测效率和准确性，为道路维护和管理提供有力支持。

关键词：深度学习；道路病害；快速检测

1 引言

在建设交通强国的道路上，我国正加速推进综合运输大通道、综合交通枢纽以及物流网络的完善。随着公路基础设施的日益完善，对公路养护服务的需求也逐年上升。道路病害检测作为全面了解道路健康状况、制定针对性养护计划的重要手段，其准确性和效率直接关乎养护工作的成效。传统的道路病害检测方法主要依赖人工视觉或基于机械传感器的检测车，存在效率低、成本高、易受环境干扰等问题。因此，研究基于深度学习的复杂路况下道路病害快速检测方法具有重要意义。

2 道路病害分析与检测方法

2.1 道路病害特性与分类详述

道路病害作为影响道路使用性能和安全性的重要因素，其类型繁多且特性各异。裂缝是道路表面最常见的病害之一，形态各异，有纵向、横向及不规则裂缝等，主要由温度应力、交通荷载或地基沉降引起。坑洼则是路面局部材料脱落形成的凹陷，多由施工质量不佳或长期磨损导致。车辙是车辆反复行驶形成的轮迹凹陷，常见于重载交通路段。松散指路面材料失去粘结力而松散脱落，与环境因素和材料质量有关^[1]。沉陷则是路面整体或局部下沉，多由地基不稳定引起。这些病害不仅影响行车舒适性和安全性，还加速道路损坏，因此，准确识别其特性和分类对制定针对性的养护策略至关重要。

2.2 道路病害检测技术的深入应用

基于深度学习的道路病害检测方法日益成熟。目标检测方法，如YOLO、Faster R-CNN等，能高效准确地识别并定位道路病害，提供病害类别和位置信息。而语义分割方法，如UNet、DeepLab等，则能更细致地划分病害区域，生成像素级的病害地图，为道路养护提供详尽的数据支持。这两种方法结合使用，既能确保病害识别的

准确性，又能提供全面的病害信息，有助于制定更科学的养护计划。

3 基于深度学习的道路病害检测模型设计

3.1 数据集来源与增强策略

3.1.1 数据集来源

为了训练一个高效、准确的道路病害检测模型，首先需要构建一个包含多种病害类型的数据集。本文的数据集主要来源于两个方面：一是公开的路面病害数据集，这些数据集由研究机构或政府部门发布，包含了大量的路面病害图像，且已经过标注，可直接用于模型训练；二是通过车载摄像头拍摄得到的路面视频，这些视频涵盖了不同时间段、不同天气条件下的路面状况。将视频进行分帧处理，并逐帧进行标注，标注内容包括病害类型、位置、大小等信息。通过这两种方式，组建了一个包含裂缝、坑洼、车辙、松散、沉陷等多种病害类别的综合数据集。

3.1.2 数据增强策略

为了提高模型的泛化能力，使其能够更好地适应各种复杂路况下的道路病害检测任务，采用了数据增强策略。数据增强是一种通过对原始数据进行一系列变换来生成新数据的方法，它可以增加数据的多样性，提高模型的鲁棒性。本文采用的数据增强策略包括旋转、翻转、缩放、裁剪等。旋转操作可以模拟不同拍摄角度下的路面图像；翻转操作可以生成镜像图像，增加数据的对称性；缩放操作可以改变图像的大小，使模型能够适应不同分辨率的输入；裁剪操作则可以从原始图像中截取不同区域的子图像，用于训练模型对局部特征的识别能力^[2]。通过这些数据增强策略，有效地扩大了数据集的规模，提高了模型的泛化能力和鲁棒性。

3.2 深度学习模型选择与改进

3.2.1 模型选择

在深度学习领域，目标检测是一个热门的研究方向，涌现出了许多优秀的目标检测模型。综合考虑模型性能、实现难度以及应用场景等因素，本文选择了YOLOv7作为基础模型。YOLOv7是一种实时目标检测模型，它在保持较高准确性的同时，具有较快的检测速度，非常适合用于道路病害检测等实时性要求较高的场景。

3.2.2 模型改进

虽然YOLOv7在目标检测领域表现出色，但直接将其应用于复杂路况下的道路病害检测任务仍存在一些挑战。为了克服这些挑战，对YOLOv7模型进行了以下改进：首先，引入ELAN-P模块。ELAN-P模块是一种高效的网络结构，通过聚合不同层次的特征来提高模型的特征提取能力。将ELAN-P模块引入YOLOv7模型中，可以有效地提高模型对复杂背景下病害目标的特征提取能力。其次，引入注意力机制。注意力机制可以使模型更加关注于输入图像中的重要区域，而忽略无关或噪声区域。在道路病害检测任务中，病害目标通常只占图像的一小部分，而背景则占据了大部分区域。通过引入注意力机制，可以使模型更加关注于病害目标区域，从而提高模型的检测准确性^[3]。此外，还对锚框设计和损失函数进行了优化。通过优化锚框设计，使其更加适应道路病害目标的形状和大小；通过改进损失函数，使其更加关注于模型的定位精度和预测准确性。最后，为了减少噪声干扰，提高模型的鲁棒性，还采用了残差收缩网络。残差收缩网络通过引入残差块和收缩机制来减少噪声干扰，得到更加纯净和有效的特征表示。将残差收缩网络引入YOLOv7模型中，可以有效地提高模型的鲁棒性。

3.3 模型训练与优化

3.3.1 模型训练

在模型训练过程中，采用了迁移学习策略和数据增强技术来加速收敛过程并提高模型的泛化能力。首先，将YOLOv7模型在大型数据集上进行预训练，使其学习到一些通用的特征表示。然后，将预训练好的模型迁移到道路病害检测任务上，通过微调模型参数来适应新任务。同时，还采用了数据增强技术来扩大数据集的规模，提高模型的泛化能力。

3.3.2 超参数调优

超参数的选择对模型的性能有着至关重要的影响。通过实验和调优来选择最佳的超参数组合。具体来说，采用网格搜索法来寻找最佳的学习率，通过实验来选择

合适的批量大小，并通过观察模型在验证集上的性能来选择合适的训练轮数。

3.3.3 模型评估与优化

训练完成后，需要对模型的性能进行评估。本文采用了mAP、召回率、精确率等评估指标来全面评估模型的性能。如果模型的mAP较低，可以通过增加训练轮数、调整学习率或改进模型结构来提高模型的性能。如果模型的召回率较低，可以通过调整锚框设计或损失函数来提高模型对正类样本的识别能力^[4]。如果模型的精确率较低，可以通过引入注意力机制或残差收缩网络来减少噪声干扰，提高模型的鲁棒性。

4 实验验证与分析

4.1 实验环境与设置

本实验采用基于深度学习的路面病害检测算法，实验环境配置如下：

硬件环境：使用NVIDIA GeForce RTX 3090 GPU进行模型训练与推理加速，搭配Intel Core i9-10900K CPU和64GB DDR4 RAM。

软件环境：操作系统为Ubuntu 20.04 LTS，深度学习框架选择PyTorch 1.9.0，CUDA版本为11.1，cuDNN版本为8.0.5。

数据集方面，采用自建的路面病害数据集，该数据集包含多种病害类型，如横向裂缝、纵向裂缝、坑槽、龟裂等，共计7319张图像，标注格式为YOLO和VOC两种。数据集被划分为训练集、验证集和测试集，比例分别为70%、15%和15%。

4.2 实验评价指标

为了全面评估模型性能，采用以下评价指标：

平均精度均值（mAP）：衡量模型在不同类别上的平均检测精度。

精确率（Precision）：正确预测为正类的样本占有所有预测为正类样本的比例。

召回率（Recall）：正确预测为正类的样本占有所有实际为正类样本的比例。

F1分数（F1 Score）：精确率和召回率的调和平均数，用于综合评估模型性能。

推理速度（FPS）：每秒处理的图像帧数，衡量模型的实时性。

4.3 实验结果与分析

4.3.1 模型性能对比

为了验证本文提出算法的有效性，将基于YOLOv8改进的路面病害检测模型与YOLOv5、Faster R-CNN等主流目标检测模型进行对比实验。实验结果如表4-1所示：

表1 检测对比

模型	mAP (%)	Precision (%)	Recall (%)	F1 Score (%)	FPS
YOLOv5	82.3	86.7	80.1	83.3	28.5
Faster R-CNN	84.1	88.2	82.5	85.2	12.3
YOLOv8 (本文)	88.6	91.5	87.3	89.3	32.7

从表4-1可以看出,本文提出的基于YOLOv8改进的路面病害检测模型在mAP、精确率、召回率和F1分数上均优于YOLOv5和Faster R-CNN模型,同时保持了较高的推理速度。这表明本文算法在复杂路况下具有更好的检测性能和实时性。

4.3.2 消融实验

为了分析模型中各个组件对性能的影响,进行了消融实验。消融实验通过系统地移除或修改模型中的某些部分(如特定的层、算法、特征等),观察这些变化如何影响模型的性能。这种方法类似于“消融”一个个体,逐步分析其对整体的影响,从而深入了解各个组件在模型中的贡献程度。实验结果如表4-2所示:

表2 消融实验

组件	mAP (%)
基线模型 (YOLOv8)	85.2
+ ELAN-P模块	86.7
+ 聚合与分发机制	87.8
+ MPDIoU损失函数	88.3
+ K-means++锚框优化	88.6

从表4-2可以看出,每个组件的引入都显著提高了模型的mAP。其中,ELAN-P模块和聚合与分发机制对特征提取和融合起到了重要作用;MPDIoU损失函数和K-means++锚框优化则进一步提升了模型的预测精度。

4.3.3 复杂路况下的检测效果

为了验证模型在复杂路况下的检测效果,选取了一些具有挑战性的图像进行测试,包括光照不均、阴影遮挡、路面纹理多变等复杂场景。表4-3展示了部分测试图像及其检测结果:

表3 检测效果

测试图像编号	病害类型	检测结果(类别及置信度)
1	横向裂缝	横向裂缝(置信度:0.95)
2	纵向裂缝+阴影	纵向裂缝(置信度:0.88),忽略阴影部分
3	坑槽+光照不均	坑槽(置信度:0.92),部分边缘受光照影响但主体识别准确
4	龟裂+复杂纹理	龟裂(置信度:0.85),准确识别复杂纹理中的龟裂区域
5	边缘裂缝+遮挡	边缘裂缝(置信度:0.90),忽略遮挡物影响

从表4-3可以看出,即使在复杂路况下,本文算法仍能准确检测出路面病害的位置和类别,且置信度较高。这表明模型具有较强的鲁棒性和泛化能力,能够适应不同路况下的检测需求。

4.4 误差分析

尽管本文算法在路面病害检测中取得了较好的效果,但仍存在一些误检和漏检情况。主要误差来源包括:(1)光照条件:极端光照条件下(如强光、逆光等),图像质量较差,导致模型难以准确识别病害。(2)病害类型:部分罕见或新型病害未在训练集中出现,导致模型无法准确识别。(3)遮挡与干扰:路面上的杂物、车辆等遮挡物以及路面纹理的干扰,可能影响模型的检测效果。针对上述误差来源,未来工作将进一步优化数据集,增加复杂路况下的图像样本,并改进模型结构以提高其鲁棒性和泛化能力。

结语

本文围绕复杂路况下的道路病害快速检测问题,深入研究了基于深度学习的检测方法。通过设计基于改进YOLOv7的道路病害检测模型,并引入注意力机制、残差收缩网络等改进策略,有效提高了模型在复杂路况下的检测性能和鲁棒性。实验结果表明,该模型在实际应用中具有显著优势。尽管本文在复杂路况下的道路病害快速检测方面取得了一定成果,但仍存在一些问题需要进一步研究。例如,如何进一步提高模型在极端恶劣环境下的检测性能?如何构建更大规模、更多样化的数据集来训练模型?未来,将继续深入研究这些问题,并探索更多先进的深度学习技术在道路病害检测中的应用。

参考文献

[1]高文堃.基于深度学习道路复杂病害识别方法的研究[J].上海公路,2023,(02):23-27+34+188.
[2]李睿鑫,张应迁,吴嘉懿,等.深度学习在道路病害检测中的应用[J].自动化应用,2024,65(19):6-9+17.
[3]王玺翔.基于深度学习的道路病害检测模型与应用研究[D].武汉轻工大学,2024.
[4]陈智勇.基于深度学习的城市道路病害智能识别和养护技术研究[J].科学技术创新,2023,(25):168-171.