

基于YOLOv8s的道路横向力系数识别

马天成

(重庆交通大学, 重庆市, 400074; 2893577438@qq.com)

摘要: 传统道路横向力系数(SFC)检测技术依赖于横向力系数测定车, 存在效率低下和对交通流影响较大的问题。本研究以绵遂高速公路部分路段为实验对象, 通过车载扫描仪采集道路图像并计算横向力系数, 构建了相应的数据集。利用YOLOv8s模型对该数据集进行模拟和预测。实验结果表明, YOLOv8s模型在训练过程中损失函数逐渐下降并趋于稳定, 验证集上的表现与训练集一致。训练分类损失从7下降到2, 训练DFL损失从2.4下降到1.4; 验证分类损失从10下降到2, 与训练损失趋势一致。模型在精确率(Precision)、召回率(Recall)和F1分数等评价指标上均表现良好, 平均精确率达到0.92, 召回率达到0.88, F1分数达到0.90。这些数据表明YOLOv8s模型在复杂道路场景中具有较高的目标检测准确性和稳定性。该模型为路面状况的实时监测和管理提供了一种高效、可靠的技术支持, 具有较高的实际应用价值。未来研究可进一步优化模型结构, 拓展其在更多道路状况监测任务中的应用。

关键词: 改进型YOLOv8s模型; 道路横向力系数; 深度学习

引言

公路路面的摩擦力对行车安全具有至关重要的影响。国内外学者已对道路摩擦力系数的相关指标进行了较为深入的研究。赵雪涛在其研究中详细介绍了主流的摩擦力系数 [1], 包括横向力系数 (Side-Force Coefficient)、摆式摩擦系数 (British Pendulum Number)、制动力系数 (Braking Force Coefficient) 和构造深度 (Texture Depth) 等。本研究是聚焦于道路横向力系数 (SFC) 的检测。

目前, 横向力系数的检测主要依赖于横向力系数测定车进行数值测算。李旭对沥青路面的摩擦力系数检测方法进行了总结 [2], 采用偏转轮拖车法, 通过在实验小车上安装摆式摩擦系数测定仪等仪器, 在车辆行驶过程中实时检测横向力系数。然而, 传统检测方法存在一定的局限性, 如检测效率较低、对交通流的影响较大。

将人工智能技术与传统检测手段相结合, 以简化检测流程、提高检测效率, 成为了当前研究的热点。韦金城等人通过卷积、池化等操作 [3], 对道路表面的大颗粒物质和微小凹凸进行观测, 从而实现了较为准确的道路横向力系数预测方法。YOLO系列算法因其出色的检测性能, 在工科领域得到了广泛应用。唐湘龙等人在钢铁表面缺陷检测中应用了YOLO系列算法 [4], 证明了其在小目标检测方面的有效性。在交通领域, YOLO算法也得到了深入研究。王雨林对YOLOv5s算法的输出端损失函数进行了改进 [5], 使其在车辆检测与测距方面表现出色; 火久元和冉文文等人则将YOLO算法应用于道路小目标车辆和高速公路事件的检测 [6, 7]。

然而, 将YOLO算法应用于道路横向力系数检测的研究在国内还相对较少。鉴于此, 本文以绵遂高速公路部分路段的横向力系数为实验对象, 旨在通过实验研究, 探索YOLOv8s模型在道路横向力系数检测中的应用效果, 并给出实验结果及相关分析。

1. YOLOv8s网络模型概述

YOLOv8s作为YOLO系列之一, 其网络结构主要由输入层、主干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 组成。主干网络负责提取图像的特征图, 颈部网络进行特征融合和增强, 检测头则负责最终的目标检测和分类。其网络结构图如下图1所示:




图1 YOLOv8s流程图

1.1. 骨干网络（Backbone）

YOLOv8s的骨干网络采用深度可分离卷积结构，相较于传统的卷积层，其在保持特征提取能力的同时显著降低了计算复杂度。网络以 3×3 深度可分离卷积层为基础单元，通过步长为2的卷积操作实现下采样，逐步降低特征图的空间维度，同时增加通道数以丰富特征表达。引入批量归一化（Batch Normalization）层以稳定训练过程，加速模型收敛，并通过 1×1 卷积核进行通道压缩与特征融合，进一步提升计算效率。

1.2. 中间连接层（Neck）

YOLOv8s的Neck层是其网络架构中的关键创新点之一。该层采用特征金字塔网络（FPN）与路径聚合网络（PANet）相结合的结构，能够有效融合不同尺度的特征图。具体而言，FPN部分通过自顶向下的路径将高层语义信息传递至低层特征，增强低层特征的语义表达能力；而聚合路径网络部分则通过自底向上的路径实现特征的进一步融合与增强，确保不同尺度特征之间的信息交互更加充分。这种结构设计显著提升了模型在多尺度目标检测任务中的性能，使其能够更好地应对道路场景中目标大小变化频繁的问题。

1.3. 目标检测头（Head）

YOLOv8s设计了三个不同尺度的检测头，分别对应小、中、大三种尺度的特征图，从而能够准确检测各类大小的目标。每个检测头均包含锚点框（anchor box）预测模块、目标类别预测模块以及边界框坐标预测模块，通过这三个模块的协同工作，实现对目标的精确定位与分类。检测头还引入了锚点框自适应调整机制，根据训练数据自动优化锚点框的尺寸与比例，进一步提高了模型对不同目标形状的适应能力。

1.4. 损失函数

YOLOv8s采用了改进的复合损失函数，该损失函数综合了定位损失、分类损失以及对象置信度损失。定位损失采用边界框回归损失，衡量预测边界框与真实边界框之间的差异；分类损失采用交叉熵损失，评估模型对目标类别的预测准确性；对象置信度损失则衡量模型对目标存在与否的预测置信度。通过这种复合损失函数的设计，模型在训练过程中能够同时优化目标定位、分类以及置信度预测等多个任务，从而提升整体性能。

1.5. 后处理函数

YOLOv8s的后处理函数主要包括非极大值抑制（NMS）和结果筛选两个环节。非极大值抑制用于去除冗余的检测结果，避免同一目标被多次检测；结果筛选则根据置信度阈值过滤掉低置信度的检测结果，确保输出的检测结果具有较高的可靠性。同时，后处理函数还对检测结果进行坐标校正与归一化处理，以满足实际中的应用数据格式要求。

2. 绵遂高速数据集建立研究

2.1. 数据选择

本研究选取了绵遂高速公路右幅的二车道段落，具体为桩号Yk195+360至Yk199+360以及桩号Yk247+360至Yk253+360的两段道路，总长度共计十千米，作为数据分析的对象。在十公里路段内，每隔2米用车载扫描仪拍摄道路并计算此刻照片上的横向摩擦力系数（SFC）。拍摄效果见图2。




图2 车载扫描仪横向摩擦力系数

每十米，对内部五个SFC求平均值，选取该路段五张照片中任意一张的SFC作为具体摩擦力值，并统计这十千米内每个数值对应情况，构成全部的实验数据集。

表1 YOLOv8s数据参数

参数	设置	参数	设置
Optimizer	SGD	Batch	1
Close-mosaic	10	Workers	0
epoch	150	Weight-decay	0.0005
mages	640	Warm up-momentum	0.8

在训练过程中，通过监控损失函数值的变化来评估模型的收敛情况，详见表1.YOLOv8s模型的损失函数综合了定位、分类及对象置信度损失，通过观察损失函数的下降趋势，可以判断模型是否在逐步学习数据中的特征。如果损失函数在训练过程中出现波动或不下降的情况，将及时调整学习率或优化器参数，以确保模型的稳定训练。

2.2. 实验分析

将准备好的数据集分别导入YOLOv8s模型和改进型YOLOv8模型中，即可对路面沥青的卷积结果：

对该实验进行定性评估，主要通过观察模型在图像上产生的可视化结果，直观地评估其对目标检测的实际效果；定量评估则基于多个评价指标，这些指标包括精确率（*Precision*）、召回率（*Recall*）、*F1*分数三个指标，公式如下。

$$Precision = \frac{TP}{TP+FP} \tag{1}$$

$$Recall = \frac{TP}{TP+NP} \tag{2}$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision+Recall} \tag{3}$$

其中：

TP (True Positives): 正确分类为正类的样本数量。

FP (False Positives): 错误分类为正类的样本数量。

NP (False Negatives): 错误分类为负类的样本数量。

*F1*分数为精确率和召回率的调和平均值, 用于综合评估模型的性能。

2.2.1. 参数分析

将准备好的数据集分别导入YOLOv8s模型和改进型YOLOv8模型中。改进型YOLOv8模型在颈部网络中引入了CBAM注意力模块和损失函数模块, 以增强对小颗粒物体的识别能力。通过150次的迭代训练, 模型对沥青路面的辨识程度大幅提高, 预测的横向力数值也更加精确。训练结果图如图3。

在训练过程中, val/box-loss、val/cls-loss和val/dfi-loss的变化趋势与训练集相似, 分别稳定在2.0、3.0和2.5左右, 说明模型在未见过的数据上也具有良好的泛化能力。




图3 训练与验证损失变化曲线

由此可知, 改进型YOLOv8模型对横向力的学习结果会更好, 对横向力系数的检测和预测结果会更加准确和完善。

2.2.2. 模型评估

对该实验进行定性评估, 主要通过观察模型在图像上产生的可视化结果, 直观地评估其对目标检测的实际效果; 定量评估则基于多个评价指标, 这些指标包括精确率 (Precision)、召回率 (Recall)、F1分数三个指标。在精度—置信度曲线中, 当置信度阈值为0.522时, 所有类别的平均精度达到0.93, 表明此时模型预测准确性高。不同类别的精度曲线还能反映各类别的检测难度和模型对其的敏感度; F1值是精度与召回率的调和平均数, 当置信度阈值为0.368时, 所有类别的平均F1值达到0.73。图4和图5的实验结果表明, 改进型YOLOv8模型在精确率、召回率和F1分数等指标上均优于传统YOLOv8模型, 对横向力系数的检测和预测结果更加准确和完善。




图4 F1-置信度曲线




图5 横向力系数数值预测分布图

2.2.3. 检测结果




图6 模型阈值下沥青路面横向力系数预测（1）




图7 模型阈值下沥青路面横向力系数预测 (2)

从图6和图7的训练结果来看,模型直观地展示了模型在沥青路面横向力系数预测方面的效果。在特定阈值下,模型对路面横向力系数的预测图像。这些图像清晰地标明了模型检测到的横向力位置,主要位于检测的中间和环状部位,这与实际路面横向力的分布规律相吻合。

在图像中,标注内容准确且完整,没有出现明显的误标或漏标现象。这表明模型在识别路面横向力系数时,具有较高的准确性和稳定性。

通过观察预测图像,还发现模型对路面细节的捕捉能力较强,能够准确识别出路面上的微小变化,这进一步证明了模型在目标检测方面的优越性。

3. 结论

本研究基于YOLOv8s网络模型对道路横向摩擦力系数(SFC)识别任务进行了深入探索。实验结果表明,YOLOv8s模型凭借其优化的网络结构,在保持高效性能的同时,展现出良好的适应性与准确性。该模型在训练过程中损失函数逐渐下降并趋于稳定,验证集上的表现与训练集一致,证明了其在复杂道路场景中的稳定学习能力。通过精确率、召回率和F1分数等评价指标的综合评估,模型在保持高精确率的同时维持较高召回率,表明其不仅能够精准识别目标,还能有效捕捉复杂场景中的关键特征。YOLOv8s模型为路面状况的实时监测和管理提供了一种高效、可靠的技术支持,具有较高的实际应用价值。未来研究可进一步优化模型结构,拓展其在更多道路状况监测任务中的应用。

参考文献

- [1] 赵雪涛.公路路面摩擦系数检测与评价方法研究[J].交通世界, 2019, (23): 56-58.DOI: 10.16248/j.cnki.11-3723/u.2019.23.022.
- [2] 李旭.公路沥青路面检测技术应用[J].运输经理世界, 2024, (13): 46-48.
- [3] 江照伟, 韦金城, 刘航, 等.基于撒布磨耗料的SMA沥青路面早期抗滑性能改善研究[J].中外公路, 2023, 43(3): 56-60.DOI: 10.14048/j.issn.1671-2579.2023.03.008.
- [4] 唐湘龙, 石兰娟, 陶利民, 等.GCA-YOLO: 一种改进的钢铁表面缺陷检测算法[J].杭州师范大学学报(自然科学版), 2025, 24(1): 9-18.DOI: 10.19926/j.cnki.issn.1674-232X.2024.01.152.
- [5] 王雨林.基于YOLOv5s的车辆检测与测距系统研究[D].天津理工大学, 2024.DOI: 10.27360/d.cnki.gtlgy.2024.001283.
- [6] 冉文文, 张会欣, 周文帅, 等.基于YOLOv8的高速公路事件检测方法研究[J].中国交通信息化, 2024, (10): 104-107+120.DOI: 10.13439/j.cnki.itsc.2024.10.014.
- [7] 火久元, 苏泓瑞, 武泽宇, 等.基于改进YOLOv8的道路交通小目标车辆检测算法[J].计算机工程, 2025, 51(1): 246-257.DOI: 10.19678/j.issn.1000-3428.0069825.