

基于改进YOLOv8的高速公路区段车辆异常行驶事件研究

常健¹, 田浩¹, 江超¹, 周齐^{2*}, 倪哲², 唐浩东¹

¹山东高速淄博发展有限公司, 山东 淄博

²山东理工大学交通与车辆工程学院, 山东 淄博

收稿日期: 2025年6月16日; 录用日期: 2025年7月16日; 发布日期: 2025年7月25日

摘要

随着高速公路通车里程和交通流量的增加, 车辆异常行驶事件引发的安全问题日益突出。传统监控手段存在效率低、漏检误检率高等不足, 而基于深度学习的计算机视觉技术为解决这一问题提供了新途径。文章提出一种基于改进YOLOv8的高速公路车辆异常行为检测方法, 通过引入Swin Transformer结构替换主干网络, 增强模型对长距离特征和时空关联的建模能力。研究构建了包含400张图像的高速公路车辆行驶事件数据集, 涵盖不同时段、天气和车辆类型。实验结果表明, 改进后的模型在精确率(92.5%)、召回率(98%)和平均精确率(mAP0.5为94.4%)等指标上显著优于原始YOLOv8模型, 能够有效提升高速公路车辆异常行为的检测精度和可靠性, 为智能交通系统的实时监控与事故预防提供了技术支撑。

关键词

高速公路, 车辆异常行为, YOLOv8, Swin Transformer, 目标检测

Research on Abnormal Driving Events of Vehicles in Highway Sections Based on Improved YOLOv8

Jian Chang¹, Hao Tian¹, Chao Jiang¹, Qi Zhou^{2*}, Zhe Ni², Haodong Tang¹

¹Shandong High Speed Zibo Development Co., Ltd., Zibo Shandong

²School of Traffic and Vehicle Engineering, Shandong University of Technology, Zibo Shandong

Received: Jun. 16th, 2025; accepted: Jul. 16th, 2025; published: Jul. 25th, 2025

*通讯作者。

文章引用: 常健, 田浩, 江超, 周齐, 倪哲, 唐浩东. 基于改进 YOLOv8 的高速公路区段车辆异常行驶事件研究[J]. 交通技术, 2025, 14(4): 502-512. DOI: 10.12677/ojtt.2025.144050

Abstract

With the increase in the mileage of expressways and traffic flow, safety issues caused by abnormal vehicle driving events have become increasingly prominent. Traditional monitoring methods suffer from low efficiency, high missed detection and false detection rates, while computer vision technology based on deep learning provides a new approach to solve this problem. This paper proposes an improved YOLOv8-based method for detecting abnormal vehicle behaviors on expressways by introducing the Swin Transformer structure to replace the backbone network, enhancing the model's ability to model long-range features and spatio-temporal correlations. A dataset of 400 images of vehicle driving events on expressways was constructed, covering different time periods, weather conditions, and vehicle types. Experimental results show that the improved model significantly outperforms the original YOLOv8 model in terms of precision (92.5%), recall (98%), and mean average precision (mAP 0.5: 94.4%), effectively improving the detection accuracy and reliability of abnormal vehicle behaviors on expressways. This study provides technical support for real-time monitoring and accident prevention in intelligent transportation systems.

Keywords

Highway, Abnormal Vehicle Behavior, YOLOv8, Swin Transformer, Object Detection

Copyright © 2025 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

随着高速公路通车里程不断增加以及交通流量日益增长,车辆在高速公路上的异常行为事件,如违规变道、超速行驶、低速行驶、停车等引发的交通事故和交通拥堵问题愈发严重[1]。传统的交通监控与管理手段在面对复杂多样的车辆行为时,存在效率低、漏检误检率高等问题[2]。利用计算机视觉和深度学习技术可以实现车辆异常行为自动检测,成为提升高速公路交通安全与管理水平的关键方向,而高质量数据集是该技术研究与应用的基础[3]。

随着深度学习的快速发展,利用计算机视觉技术中的卷积神经网络(Convolutional Neural Network, CNN)、YOLO (You Only Look Once)系列等目标检测模型可快速准确检测图像或视频中的车辆及行人异常行为,对提高交通安全,优化交通信号设备,改进交通管理具有重要意义。2023年Ma等人[4]提出了一种长短期记忆残差(Long Short-Term Memory-Residual, LSTM-R)算法来实时检测异常驾驶行为。而YOLO系列自2015年被首次提出后更是广泛应用于车辆异常行为检测方面,何佳桥和葛晓东[5]基于改进的YOLOv5利用无人机获取的图像进行车辆检测,郭雨[6]更是建立了一种基于YOLOv5轻量化的车辆检测方法。

相比于其他YOLO系列,YOLOv8凭借其精确度更高、速度更快等优势,被广泛应用于智能安防与监控[7]、智能交通和自动驾驶以及无人机巡检等众多领域。Mane等人[8]提出了一种集成模型,使用YOLOv8方法进行交通事故的检测。Guo等人[9]首先采用FasterNet网络代替YOLOv8骨干网络并应用于车辆自动驾驶中的自动识别技术。Dou等人[10]针对城市交通监控系统中的车辆和行人检测问题,提出了一种改进的YOLOv8模型,引入多尺度特征融合模块和改进的非极大值抑制(Non-Maximum Suppression, NMS)算法,通过实验验证了改进后模型的检测性能良好。

2. 基于改进的 YOLOv8 检测方法

2.1. YOLOv8 网络结构

YOLOv8 延续了 YOLO 系列经典的三段式架构, 但通过模块化改进实现了性能的跃升, 其算法结构主要包括主干网络(Backbone)、颈部网络(Neck)和检测头(Head)三部分, 如图 1 所示。在主干网络中, YOLOv8 在 YOLOv5 的 CSPDarknet53 基础上, 将 C3 模块替换为 C2f (Cross-convolution with 2 filters)模块, 大大增强了梯度流动; 在颈部网络中, YOLOv8 结合路径聚合网络(PANet)和特征金字塔网络(FPN), 通过自顶向下和自底向上的双向特征融合增强了多尺度信息交互[11]。同时 YOLOv8 采用的解耦头(Decoupled Head)将分类与回归任务分离为独立分支, 降低了任务耦合的干扰, 从而提升检测精度[12]。




Figure 1. YOLOv8 algorithm structure diagram

图 1. YOLOv8 算法结构图

然而, YOLOv8 其主干网络虽然能高效提取局部特征, 但对远距离特征依赖关系的建模能力较弱。为解决这一问题, 本文基于 YOLOv8 算法网络结构通过 Swin Transformer 结构替换 Backbone 网络实现关键区域特征增强与时空关联建模针对高速公路场景中车辆异常行驶行为进行检测, 从而判定车辆运行状态, 其改进后网络结构如图 2 所示。

2.2. Swin Transformer 基本原理

Swin Transformer 是一种基于 Transformer 架构的模型[13], 它引入了滑动窗口(Shifted Window)机制, 使得 Transformer [14]能够处理计算机视觉任务, 如目标检测、图像分割等。相较于传统的 Transformer 在处理图像时, 其由于计算量与图像分辨率的平方成正比, 难以直接应用于高分辨率图像, Swin Transformer 则通过将图像划分为不重叠的窗口(Window), 在每个窗口内进行自注意力计算, 大大降低了计算复杂度。

同时,滑动窗口机制使得相邻窗口之间能够进行信息交互,增强了模型对全局信息的捕捉能力。




Figure 2. Structure diagram of the improved YOLOv8 algorithm

图 2. 改进后 YOLOv8 算法结构图

在 Swin Transformer Backbone 中,输入 640×640 的图像后 Patch Partition 将输入图像划分为不重叠的小块(Patch),每个小块作为一个基本单元后续处理,Linear Embedding 对划分后的 Patch 进行线性变换,将其映射到高维特征空间,得到初始特征表示。每个 Stage 都包含 Patch Merging、基于窗口的多头自注意力机制(W-MSA)、移位窗口的多头自注意力机制(SW-MSA)和多层感知机(MLP)。Patch Merging 用于下采样,减少特征图分辨率并增加通道数;W-MSA 在固定窗口内计算自注意力,捕捉局部信息;SW-MSA 通过移位窗口打破窗口边界,实现跨窗口信息交互;MLP 对特征进行非线性变换,进一步提取特征,随着 Stage 的推进,逐步提取更高级、更抽象的特征。

2.3. 车辆异常判定原理

本文通过非极大值抑制(Non-Maximum Suppression, NMS)算法过滤重复的检测框,保留置信度高且无重叠的边界框,最终通过统计图像中所有有效边界框的数量,基于多组车辆计数结果判定数量异常实现车辆数量的识别。

(1) 关键参数设置

在目标检测中,模型可能因为车辆不同部位特征或检测阈值设置导致对同一车辆生成多个重叠的边界框。NMS 算法通过抑制重叠度高的低置信度框,保留最优检测结果,避免重复计数,本文置信度阈值(Confidence Threshold)设置为 0.5,仅保留置信度 ≥ 0.5 的框。交并比(IoU, Intersection over Union)阈值是衡量两个边界框的重叠程度,当两个框的 IoU 超过设定阈值时,认为它们检测的是同一目标,其计算公式为:

$$\text{IoU} = \frac{\text{重叠区域面积}}{\text{并集区域面积}} \quad (1)$$

(2) 车辆数量统计

对所有类别(car、truck 等)完成 NMS 处理后,统计各组剩余的有效检测框数量,即为图像中对应类别的车辆数量。总车辆数 = car 组有效框数 + truck 组有效框数。

(3) 车辆数量异常判定的底层逻辑

车辆数量异常判定的底层逻辑为“空间-时间关联性验证”。若监测点间存在车流关联(如同一断面的上下游、互通区的进出车流),理论上车辆数应符合交通流规律(如车流连续时,上下游计数差异应在合理阈值内);若两组计数结果偏离规律(差异超出阈值),则判定为数量异常,可能对应漏检、误检、交通事件等情况,其中差异度计算公式如下。

$$\text{差异度} = \left| \frac{N_{\text{上游-下游}} - N_{\text{下游}}}{N_{\text{上游}}} \right| \times 100\% \tag{2}$$

若为“进入-驶出”关系,公式同理,替换为 $N_{\text{进入}}$ 与 $N_{\text{驶出}}$ 。

3. 案例应用

3.1. 高速公路区段车辆行驶事件数据集建立

基于深度学习的检测模型效果很大程度上受车辆行驶数据集的影响,为确保模型具有足够准确和充足的数据,本文构建高速公路区段车辆行驶事件数据集,提升模型检测精度与泛化能力,从而推动智能交通系统在高速公路场景下的应用,为交通管理部门提供科学决策依据,辅助交通指挥与事故预防,保障高速公路安全、高效运行。

(1) 车辆行驶数据集建立

本研究在利用高速公路选定地点的高清监控摄像头,进行参数设置和设备调试,确保设备正常运行且画面质量符合要求,收集基于高速公路环境下的车辆行驶数据,并进行筛选分类便于后续数据处理与检索,数据集制作流程如图3所示。




Figure 3. Flow chart of data set establishment
图3. 数据集建立流程图

(2) 车辆图像数据帧截取及筛选

为实现行驶车辆异常检测需要大量的高速公路环境下的车辆图像数据,本文获取的高速公路监控视频来自山东高速淄博发展有限公司,选取济潍高速淄川区路段(S6 K35 + 850 上行、S6 K38 + 000 下行、S6 K35 + 120 上行),通过采集一天中不同时段、不同方向和不同天气状况下的高速公路车流图像获取原始数据并进行筛选,数据样本如图4所示。



Figure 4. An image of the highway section was captured
图 4. 高速公路区段截取图像

(3) 图像增强

由于不同光照条件下，图像整体亮度存在差异，需要通过改变图像像素的灰度值来实现亮度调整，提升图像整体亮度均匀性，让在不同光照条件下拍摄的车辆图像都能具有合适的亮度，便于模型准确识别车辆特征，避免因过暗或过亮导致特征丢失或误判。

(4) 数据标注与划分

为满足高速公路车辆行驶事件检测模型的训练需求，需要将图像数据标注与划分构建高质量数据集，使用 LabelImg 标注工具，绘制车辆目标矩形框并标注车辆类别，生成初始 XML 标注文件，如图 5 所示。采用分层随机划分策略，根据车辆行驶事件类别对数据进行划分生成新的数据子集，包括训练集 500 张，测试集 300 张和验证集 200 张，总计 1000 张图像。通过上述生成高速公路环境下车辆行驶事件的数据集后，需要对划分后的 txt 标注文件，再进行坐标归一化处理以适配 YOLO 模型的输入要求。



Figure 5. Calibration of image data
图 5. 图像数据标定

3.2. 实验环境配置

本实验基于 Python 语言进行编程对各参数进行设置，配置实验环境如表 1 所示。

Table 1. Experimental environment configuration table
表 1. 实验环境配置表

设备类别	设备名称	内容
硬件环境	CPU	Intel(R)Core(TM) i7-8750h
	显存	6 GB

续表

硬件环境	内存	512 GB
	GPU	NVIDIA GeForce GTX 1060
软件环境	操作系统	Windows11
	平台	pytorch1.21.0
	Cuda 版本	torch-2.4.1 + cu124

实验中图像输入尺寸为 640×640 ，每次输入图片数量为 8，设置优化器 Transformer，初始学习率设置为 0.01，循环学习率为 0.01，批次大小 batch size 为 16，训练轮数 epoch 为 500 次，衰减系数 0.005。

3.3. 评价指标

本文采用 3 个评价指标分别为精确率(Precision, P)、召回率(Recall, R)和平均精确率(Mean Average Precision, mAP) [15] [16]。其中在式(2)中 TP 表示模型正确预测为正例的样本数量， FP 表示模型错误地将负例预测为正例的样本数量；式(3)中 FN 表示模型错误地将正例预测为负例的样本数量， N 为类别数量。

$$P = \frac{TP}{TP + FP} \tag{3}$$

$$R = \frac{TP}{TP + FN} \tag{4}$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{5}$$

3.4. 实验结果与分析




Figure 6. Model training diagram
图 6. 模型训练图

图 6 为模型训练图，横坐标为训练轮次 epoch，纵坐标为损失值，包括边框损失曲线(train/box_om 和 train/box_oo 曲线)、分类损失曲线(train/cls_om 和 train/cls_oo 曲线)、分布匹配损失曲线(train/dfl_om 和 train/dfl_oo 曲线)、平均精确率曲线包括 metrics/mAP50(B)曲线和 metrics/mAP50-95(B)曲线以及精确率曲

线 metrics/precision (B)和召回率曲线 metrics/recall (B)。从图中可以看出,随着训练迭代次数的增加,各损失值显著降低,精确率与召回率均呈逐步上升趋势,表明在高速公路区段车辆行驶事件检测的模型训练过程中,该模型能够有效提升对高速公路车辆行驶事件的检测能力,包括更准确的定位、更精准的分类以及更低的误检和漏检率,增加了预测的可靠性。




Figure 7. The P-R curve

图 7. P-R 曲线图



Figure 8. Visualization of the detection results

图 8. 检测结果可视化图

图 7 为测试集精确率 - 召回率(Precision-Recall, P-R)曲线图,从图中可以看出随着召回率的增加,精

确率呈现下降趋势，且图中所有分类类别的准确率为 94.4%，对于 truck 和 car 类型车辆的检测效果良好，表面该模型有助于准确识别对应类型车辆的相关行驶事件，检测结果可视化见图 8。

在测试集中选取了 16 幅图像进行检测结果的可视化，图像中分别包括 car 和 truck 类行驶车辆，可以看出该模型在高速公路环境下的车辆识别能力表现较好。

图 9 中呈现了高速公路不同位置的监测画面(S8K3B + 000 下行、S8K35 + 120 上行等)，建立时间关联为同一段检测数据，空间关联为互通区“进入 - 驶出”关系，运用 NMS 算法实现高速公路环境下车辆数量识别技术，将检测框按类别(car 和 truck)分组，对每组独立执行 NMS，按置信度从高到低排列检测检测框，通过交并比(IoU)衡量框间重叠程度，保留置信度最高的框作为“最优框”，剔除与最优框 IoU 超过阈值 0.6 且置信度较低的重叠框，直至所有框处理完毕。

例如，图 9 画面 1 中上游计数 $N_1 = 5$ ，画面 2 (下游)计数 $N_2 = 2$ ，差异度 $|(5 - 2)/5| = 60\% > 20\%$ 。

车辆异常判定逻辑，若车流无特殊事件(如出口分流)，则可能存在：

- (1) 下游监测点漏检(模型对特定车辆识别失败，如夜间反光干扰、远距离小目标)；
- (2) 上游监测点误检(模型将非车辆目标判定为车辆，如广告牌、护栏阴影)；
- (3) 发生的交通事件：事故导致车辆停滞在上游，未流向下游。



Figure 9. Abnormal number of vehicles
图 9. 车辆数量异常图

3.5. 实验精度结果对比

Table 2. Comparison of experimental results
表 2. 实验结果对比

模型	P/%	R/%	mAP 0.5/%	mAP 0.5:0.95/%
YOLOv5	79.1	90	80.3	56.2
YOLOv8	82.3	96	83.1	60.1
改进 YOLOv8	92.5	98	94.4	74.5

为进一步验证改进后 YOLOv8 模型的性能效果, 将其与基础模型进行对比获得表 2 和图 10。由表 2 可知无论是在单个指标精确率 P 和召回率 R 上, 还是在综合指标平均精确率 mAP 上, 改进 YOLOv8 模型的性能指标都比 YOLOv5 模型以及原始 YOLOv8 模型要高, 其检测性能更优, 冗余框显著减少, 检测结果更可靠, 检测结果对比如图 10 所示。




Figure 10. Comparison of the detection results
图 10. 检测结果对比图

4. 总结

针对高速公路车辆异常行驶事件检测需求, 本文提出一种基于改进 YOLOv8 的检测方法, 通过替换主干网络提升模型对长距离特征和时空关联的建模能力, 将模型应用到实际高速公路环境中进行验证。通过可视化实验结果可知, 改进 YOLOv8 模型可提升高速公路智能监控效率, 有助于实时异常事件检测, 对交通流量分析、事故预防、智慧交通系统等提供技术支持。

参考文献

- [1] 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.
- [2] 任安虎, 李宇飞, 陈洋. 改进 YOLOv8 的高速公路交通异常事件检测[J]. 激光杂志, 2025, 46(1): 84-90.
- [3] 温美东. 基于机器视觉的交通检测技术及应用研究[J]. 交通技术, 2024, 13(6): 388-394.
- [4] Ma, Y., Xie, Z., Chen, S., Qiao, F. and Li, Z. (2023) Real-Time Detection of Abnormal Driving Behavior Based on Long Short-Term Memory Network and Regression Residuals. *Transportation Research Part C: Emerging Technologies*, **146**, Article ID: 103983. <https://doi.org/10.1016/j.trc.2022.103983>
- [5] 何佳桥, 葛晓东. 基于改进 YOLOv5 用于无人机图像的实时车辆检测[J]. 软件工程与应用, 2023, 12(5): 705-713.
- [6] 郭雨. 基于轻量化改进型 YOLOv5 的车辆检测方法[J]. 建模与仿真, 2023, 12(3): 1840-1849.
- [7] 毛紫薇, 周正康, 唐加山. 基于改进 YOLOv8 的公路车辆火灾检测算法研究[J]. 无线电工程, 2025, 55(5): 920-927.
- [8] Mane, D.T., Sangve, S., Kandhare, S., Mohole, S., Sonar, S. and Tupare, S. (2023) Real-Time Vehicle Accident Recognition from Traffic Video Surveillance Using YOLOV8 and OpenCV. *International Journal on Recent and Innovation Trends in Computing and Communication*, **11**, 250-258. <https://doi.org/10.17762/ijritcc.v11i5s.6651>
- [9] Guo, H., Zhang, Y., Chen, L., et al. (2024) Research on Vehicle Detection Based on Improved YOLOv8 Network.
- [10] Dou, H., Chen, S., Xu, F., Liu, Y. and Zhao, H. (2025) Analysis of Vehicle and Pedestrian Detection Effects of Improved YOLOv8 Model in Drone-Assisted Urban Traffic Monitoring System. *PLOS ONE*, **20**, e0314817. <https://doi.org/10.1371/journal.pone.0314817>
- [11] 冯晶. 基于 YOLOv8 的航拍车辆检测技术研究[J]. 计算机科学与应用, 2023, 13(12): 2399-2407.
- [12] 陈伟, 王晓龙, 张晏玮, 等. 基于改进 YOLOv8 的高速公路服务区车辆违停检测[J]. 计算机工程, 2024, 50(4): 11-19.

-
- [13] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., *et al.* (2021) Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, 10-17 October 2021, 9992-10002. <https://doi.org/10.1109/iccv48922.2021.00986>
 - [14] Srinivas, A., Lin, T., Parmar, N., Shlens, J., Abbeel, P. and Vaswani, A. (2021) Bottleneck Transformers for Visual Recognition. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 16514-16524. <https://doi.org/10.1109/cvpr46437.2021.01625>
 - [15] 冯迎宾, 刘艾妮. 基于 YOLOv8n 的夜间车辆检测[J]. 沈阳理工大学学报, 2025, 44(2): 1-6+12.
 - [16] 罗杨, 王威威, 李熹. 基于改进 YOLOv8 的夜间车辆检测方法[J]. 工业控制计算机, 2025, 38(3): 80-82.