

基于云边端协同与改进YOLOv10的高速公路车辆类型识别系统设计

张宏君¹, 牛 蕾², 杨 娜^{3*}

¹河北高速公路集团有限公司, 河北 石家庄

²河北高速公路集团有限公司承德分公司, 河北 承德

³哈尔滨工业大学汽车工程学院, 山东 威海

收稿日期: 2026年9月15日; 录用日期: 2026年10月19日; 发布日期: 2026年10月28日

摘 要

针对高速公路交通监控场景中车辆类型识别实时性不足、人工统计效率较低以及云端集中处理压力较大的问题, 本文设计了一种基于云边端协同架构的高速公路车辆类型识别系统, 并构建了CBAM-WIoU-YOLOv10车辆目标检测与类型识别模型。系统包括端侧视频采集、边侧模型推理和云侧结果展示与统计分析三个层级, 将车辆检测与类型识别任务部署于边缘侧完成, 仅向云侧上传车辆类别、置信度、检测时间和设备编号等结构化识别结果, 从而有助于降低原始视频集中上传造成的网络带宽压力。针对高速公路监控图像中车辆尺度变化明显、背景干扰较强以及部分类别外观相似等问题, 本文在YOLOv10m基础上引入CBAM注意力机制, 以增强模型对车辆关键特征区域的关注能力; 同时采用WIoU损失函数优化边界框回归过程, 提高车辆目标定位精度。实验基于包含6类车辆目标的数据集开展训练与验证, 车辆类别包括小型车辆、中型车辆、大型车辆、小型货车、大型货车和油罐车。实验结果表明, 改进模型在6类车辆目标上的精确率(Precision)、召回率(Recall)、mAP@0.5和mAP@0.5:0.95分别达到93.45%、89.82%、96.35%和82.49%, 推理速度达到78.1帧/秒(FPS)。结果表明, 所提模型在检测精度与推理效率之间取得了较好平衡, 能够为高速公路车辆类型识别和交通运行统计分析提供有效的模型与数据支撑。

关键词

车辆类型识别, YOLOv10, CBAM注意力机制, WIoU损失函数, 云边端协同, 目标检测

Design of a Highway Vehicle Type Recognition System Based on Cloud-Edge-End Collaboration and Improved YOLOv10

*通讯作者。

文章引用: 张宏君, 牛蕾, 杨娜. 基于云边端协同与改进 YOLOv10 的高速公路车辆类型识别系统设计[J]. 软件工程与应用, 2026, 15(5): 772-786. DOI: 10.12677/sea.2026.155072

Hongjun Zhang¹, Lei Niu², Na Yang^{3*}

¹Hebei Expressway Group Co., Ltd., Shijiazhuang Hebei

²Chengde Branch, Hebei Expressway Group Co., Ltd., Chengde Hebei

³School of Automotive Engineering, Harbin Institute of Technology, Weihai Shandong

Received: September 15, 2026; accepted: October 19, 2026; published: October 28, 2026

Abstract

To address the problems of insufficient real-time performance in vehicle type recognition, low efficiency of manual traffic statistics, and high computational pressure caused by centralized cloud processing in highway traffic monitoring scenarios, this paper designs a highway vehicle type recognition system based on a cloud-edge-end collaborative architecture and develops a CBAM-WIoU-YOLOv10 model for vehicle object detection and type recognition. The system consists of three layers: video acquisition at the end layer, model inference at the edge layer, and result visualization and statistical analysis at the cloud layer. Vehicle detection and type recognition tasks are performed at the edge layer, while only structured recognition results, including vehicle category, confidence score, detection time, and device ID, are uploaded to the cloud platform, thereby helping to reduce the network bandwidth pressure caused by the centralized transmission of raw video streams. To address significant vehicle-scale variations, complex background interference, and similar appearances among certain vehicle categories in highway monitoring images, the CBAM attention mechanism is introduced into YOLOv10m to enhance the model's ability to focus on key vehicle feature regions. Meanwhile, the WIoU loss function is employed to optimize bounding-box regression and improve vehicle localization accuracy. Experiments are conducted on a dataset containing six vehicle categories, including small vehicles, medium-sized vehicles, large vehicles, small trucks, large trucks, and tank trucks. The experimental results show that the improved model achieves a Precision of 93.45%, a Recall of 89.82%, an mAP@0.5 of 96.35%, and an mAP@0.5:0.95 of 82.49%, while maintaining an inference speed of 78.1 frames per second (FPS). These results demonstrate that the proposed model achieves a favorable balance between detection accuracy and inference efficiency, providing effective model and data support for highway vehicle type recognition and traffic operation analysis.

Keywords

Vehicle Type Recognition, YOLOv10, CBAM Attention Mechanism, WIoU Loss Function, Cloud-Edge-End Collaboration, Object Detection

Copyright © 2026 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

随着高速公路数字化与智能化建设持续推进,道路交通运行状态感知与管理对视频智能分析技术提出了更高要求[1]。高速公路沿线通常布设有大量视频监控设备,传统人工查验与集中式处理方式在处理效率、实时性和大规模视频数据处理方面存在一定局限[2][3]。利用目标检测算法对车辆进行自动识别与宏观统计,对交通运行分析和路网管理决策具有重要的工程价值[4][5]。随着视频数据规模持续增长,传统集中式云端处理模式容易面临网络传输量大、处理时延和云端计算压力等问题[6][7]。因此,引入边缘

计算理念, 构建云边端协同的智能交通监控网络, 将部分计算任务前置至边缘侧, 成为降低传输压力和提高系统响应效率的重要技术途径。

近年来, 深度学习技术在计算机视觉与目标检测领域取得了突破性进展[8]。以 Faster R-CNN 为代表的两阶段算法虽然检测精度较高, 但在复杂的实时交通监控场景中部署成本和延迟相对较高[9]。以 YOLO (You Only Look Once) 系列为代表的单阶段目标检测算法, 凭借在检测精度与推理效率之间的良好平衡, 被广泛应用于车辆与道路目标识别任务中[10]-[12]。作为该系列的最新迭代网络, YOLOv10 在保持高效推理的同时, 实现了无非极大值抑制(NMS-free)设计[13], 进一步优化了检测结构。然而, 针对高速公路监控图像中车辆尺度变化明显、背景干扰较强以及部分类别外观相似等问题, 原始检测模型在复杂工况下仍易出现漏检或误判[14] [15]。为了改善复杂场景下的特征表达与目标定位, 大量研究表明, 引入如 CBAM (Convolutional Block Attention Module) 等注意力机制能够有效增强模型对关键特征的聚焦, 并抑制复杂背景干扰[16]-[18]; 此外, 在边界框回归优化方面, 已有研究将 WIoU (Wise-IoU) 等损失函数应用于交通目标与车辆检测任务, 通过改进边界框回归策略提升检测性能[18] [19]。此外, 针对目标检测模型在实际部署中面临的计算开销和多尺度目标识别问题, 已有研究分别从轻量化 YOLO 与边界框回归优化[20] 以及改进 YOLO 多尺度目标检测[21] 等方面开展研究, 为兼顾模型检测精度、计算效率与多尺度目标适应能力提供了参考。

针对上述应用挑战与技术痛点, 本文以高速公路交通运行分析的实际需求为导向, 设计了一种基于云边端协同架构的车辆类型识别系统, 并提出改进的 CBAM-WIoU-YOLOv10 车辆检测模型。

本文的主要研究创新与特色体现在以下三个方面:

(1) 云边端协同架构设计: 面向高速公路视频监控场景, 设计由端侧视频采集、边侧模型推理和云侧结果汇聚与统计分析组成的车辆类型识别架构。将车辆检测与类型判断任务部署于边侧, 仅向云侧传输车辆类别、置信度、检测时间和设备编号等结构化结果, 为降低原始视频集中传输压力和提高识别结果输出及时性提供系统方案。

(2) 检测模型多维改进: 在轻量化的 YOLOv10m 基础网络中引入 CBAM 注意力机制, 从通道和空间双重维度增强模型对车辆关键特征区域的关注能力, 有效克服复杂环境干扰; 同时采用 WIoU 损失函数优化边界框回归过程, 自适应调节样本梯度分配, 显著提高了车辆目标的定位精度与回归稳定性。

(3) 兼顾精度与实时性的应用落地: 实验基于 6 类真实车辆目标(包括小型车辆、中型车辆、大型车辆、小型货车、大型货车和油罐车)数据集开展训练与验证。改进模型在上述 6 类目标上的 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别达到 93.45%、89.82%、96.35%和 82.49%, 推理帧率保持在 78.1 FPS。结果表明该模型在检测精度与推理效率之间取得了较好平衡, 能够为高速公路车辆类型识别和交通运行统计分析提供可靠的数据与算法支撑。

2. 云边端车辆类型识别系统设计

2.1. 应用场景与系统需求

本文面向高速公路车辆类型识别场景, 设计一种基于云边端架构的车辆识别系统。高速公路沿线通常布设有视频监控设备, 能够持续获取车辆通行图像或视频数据。随着交通流量增加, 人工查看监控视频存在效率低、实时性不足和统计困难等问题, 因此有必要利用目标检测算法对车辆目标进行自动识别。

本文系统主要完成车辆检测和类型识别任务。端侧摄像机或视频源负责采集车辆图像, 边侧设备部署 YOLOv10 车辆识别模型, 完成车辆目标检测和类别判断, 云侧平台负责识别结果的汇聚、展示和统计分析。系统输出内容主要包括车辆类别、置信度和检测框信息, 可用于车辆类型统计和后续交通运行分析。系统需求分析见表 1。

Table 1. Analysis of system demand
表 1. 系统需求分析表

需求类型	具体内容
视频输入需求	支持摄像机视频流或本地测试视频输入
边侧识别需求	在边侧设备中完成车辆检测和类型识别
实时性需求	减少视频传输延迟，提高识别结果输出的及时性
结果输出需求	输出车辆类别、置信度和检测框信息
云侧应用需求	支持识别结果汇聚、展示和统计分析

2.2. 云 - 边 - 端系统总体架构

针对高速公路视频数据量大、实时性要求较高以及云端集中处理压力较大的特点，本文采用云 - 边 - 端协同架构构建车辆类型识别系统。系统整体由端侧视频源、边侧识别设备和云侧平台三部分组成，各层级按照数据流向和功能分工协同完成车辆检测、类型识别和结果应用。系统总体架构如图 1 所示。




Figure 1. Overall architecture of the cloud-edge-end vehicle type recognition system
图 1. 云 - 边 - 端车辆类型识别系统总体架构图

端侧视频源主要包括高速公路摄像机和本地视频输入，用于获取车辆通行图像或视频数据。端侧采集到的视频数据首先传输至边侧识别设备。边侧识别设备作为系统的核心处理层，主要包括数据接入、视频读取、图像预处理、YOLOv10 推理和结果输出等模块。其中，数据接入模块负责接收视频流或本地文件；视频读取模块对输入视频进行帧提取；图像预处理模块完成图像缩放、归一化和格式转换等操作；YOLOv10 推理模块完成车辆检测与类型识别；结果输出模块生成车辆类别、置信度和检测框等识别结果。

同时, 边侧设备可将识别结果、运行日志和截图等信息进行本地存储, 便于后续查看和问题追踪。

云侧平台主要负责对边侧上传的结构化识别结果和设备状态数据进行接收、存储、展示和统计分析。同时, 云侧可结合设备状态、运行日志和告警信息对系统运行情况进行辅助管理, 为后续车辆类型统计和交通运行分析提供数据支持。

与直接将原始视频全部上传至云端处理相比, 本文系统将车辆检测与类型识别任务部署在边侧完成, 仅将识别结果和状态信息上传至云侧平台, 能够减少网络传输压力, 提高识别结果输出的及时性。该架构既保留了边侧实时处理能力, 又支持云侧集中管理和结果应用, 适合高速公路车辆类型识别场景。

2.3. 关键技术实现

在云-边-端总体架构基础上, 为进一步明确系统的实现方式, 本文从边-云通信、边缘端模型部署以及云端数据处理与存储三个方面进行关键技术设计。

(1) 边-云通信与数据格式。边缘节点完成车辆检测与类型识别后, 不直接上传连续原始视频, 而是将识别结果以结构化数据形式发送云端。边-云之间采用 MQTT 协议进行实时数据传输, 利用其发布/订阅机制实现边缘设备与云端平台之间的数据交互。识别结果采用 JSON 格式进行封装, 主要包括设备编号、检测时间、图像帧编号、车辆类别、置信度和检测框坐标等信息。对于运行日志、异常截图等辅助数据, 可通过 HTTP/HTTPS 接口按需上传。该方式能够在满足识别结果传输需求的同时, 减少原始视频持续上传所产生的网络带宽开销。

(2) 边缘端模型部署与推理优化。本文车辆识别模型在 PyTorch 框架下完成训练, 部署时可将训练得到的模型转换为 ONNX 格式, 并采用 NVIDIA TensorRT 进行边缘端推理优化。TensorRT 可通过计算图优化、算子融合及低精度计算等方式降低模型推理开销。在支持相应硬件的条件下, 可采用 FP16 推理方式, 在保持模型检测性能的同时进一步提高推理效率。边缘端依次完成视频读取、图像预处理、模型推理和识别结果输出, 并将结构化识别结果上传至云端平台。需要说明的是, 本文实验中的推理性能仍基于 NVIDIA GeForce RTX 3060 GPU 和 PyTorch 环境获得, TensorRT 主要作为实际边缘设备部署时的模型优化方案, 其具体加速效果仍需结合真实硬件进行进一步验证。

(3) 云端数据处理与存储。云端平台主要负责边缘节点识别结果的接收、存储、查询和统计分析。系统可采用 FastAPI 构建后端数据服务, 并对接收到的车辆识别结果进行解析与校验。结构化识别数据采用 MySQL 数据库进行持久化存储, 主要保存车辆类别、置信度、检测时间、设备编号及相关检测信息; 对于设备状态和短周期统计结果等高频访问数据, 可采用 Redis 进行缓存。基于上述数据, 云端进一步完成不同车辆类型数量统计、车型占比分析、分时段车流趋势分析以及设备状态管理, 并将分析结果提供给云侧可视化界面。

通过上述技术设计, 系统形成了“边缘端实时识别-结构化结果传输-云端集中存储与统计分析”的处理流程, 使云-边-端各层之间具有较为明确的数据交互和技术实现方式。

3. 基于改进 YOLOv10 的车辆类型识别方法

第 2 章对云边端车辆类型识别系统的总体架构进行了设计, 明确了端侧视频采集、边侧车辆识别和云侧结果应用的功能分工。在该系统中, 部署于边缘节点的车辆识别模型是实现车辆目标检测与类型判断的核心模块。为了满足高速公路场景下车辆识别对检测准确性和实时性的双重需求, 本文以单阶段目标检测模型 YOLOv10 为基础, 针对复杂交通监控场景下的特征提取与目标定位难题进行轻量化改进, 构建了 CBAM-WIoU-YOLOv10 车辆类型识别模型。本章主要对改进模型的具体架构、车辆识别类别设置以及车辆类型识别的整体流程进行详细阐述。

3.1. 改进 YOLOv10 模型设计

原始 YOLOv10 在目标检测任务中具有较好的检测精度和推理效率，但在高速公路车辆类型识别场景中，仍然存在车辆尺度变化明显、背景干扰较强以及部分类别外观特征相似等问题。尤其是在远距离监控画面中，车辆边缘和局部特征极易受到光照变化和遮挡因素的影响，使得常规网络容易出现漏检或误检。

针对上述问题，本文在 YOLOv10 的基础架构上进行针对性改进，构建了 CBAM-WIoU-YOLOv10 车辆类型识别模型。改进主要包括两个方面：一是在网络深层特征提取阶段引入 CBAM 注意力机制，增强模型对车辆关键特征的聚焦能力；二是在边界框回归过程中采用 WIoU 损失函数替代原始损失函数，以提升复杂场景下的目标定位精度。改进后的模型整体网络结构如图 2 所示。




Figure 2. Network architecture of the improved CBAM-WIoU-YOLOv10 model
图 2. 改进后的 CBAM-WIoU-YOLOv10 模型网络结构图

CBAM 注意力模块由通道注意力(Channel Attention)和空间注意力(Spatial Attention)两部分串联组成。在网络拓扑设计上，本文将 CBAM 模块嵌入至 YOLOv10 骨干网络(Backbone)的深层特征输出端。这一设计旨在模型进行多尺度特征融合前，对包含丰富语义信息的深层特征进行有效“提纯”。通道注意力帮助模型聚焦于区分不同车辆类型的关键特征通道，空间注意力则用于抑制复杂的路面背景噪声。通过这种即插即用的轻量化模块，在不显著增加计算量的前提下，有效提升了网络对车辆目标的特征表达能力。

此外，在目标检测任务中，检测框的定位精度直接决定了识别结果的可靠性。为进一步优化车辆目标定位效果，本文引入 WIoU 损失函数优化边界框回归过程。WIoU 具有动态非单调聚焦机制，能够根据样本质量对回归损失进行自适应加权调整。该机制促使模型在训练中更加关注普通质量有效样本的边界框优化，同时降低极端低质量样本(如严重遮挡车辆)对训练的不利影响，从而提高模型在遮挡场景下的检测框回归鲁棒性。

综上所述，本文改进的 YOLOv10 模型通过引入注意力机制和优化损失函数，针对性地解决了高速公路场景下的特征提取与定位难题。结合 YOLOv10 原生的无非极大值抑制(NMS-free)高效设计，该模型在保持较高推理速度的同时提升了检测精度，为后续边缘硬件部署和交通系统的实际应用提供了可行的算法支撑。

3.2. 车辆识别类别设置

车辆识别类别设置是模型训练与后续交通数据分析的重要基础。如第 2.1 节所述,本系统的核心应用在于高速公路的车流量统计与交通运行分析。在这类全局路况感知场景中,管理部门主要关注道路上不同大类车辆(如客运乘用车、普通货运车、油罐车等专用货运车辆)的宏观分布密度与流量结构,用以评估道路承载能力并优化交通疏导策略。因此,本文模型基于车辆的视觉轮廓与几何外形特征进行类别划分,这种二维视觉层面的分类方式能够较好适应高速公路视频结构化处理的实际业务需求。

本文实验数据集共包含 6 类车辆目标,原始标签分别为 tiny-car、mid-car、big-car、small-truck、big-truck 和 oil-truck。结合前述的交通流统计分析需求,本文将原始英文标签与论文正文中的中文表述进行了规范化映射,具体对应关系如表 2 所示。

Table 2. Vehicle recognition category settings
表 2. 车辆识别类别设置表

原始标签	论文表述	说明
tiny-car	小型车辆	外观尺寸较小的乘用车目标
mid-car	中型车辆	外观尺寸中等的乘用车目标
big-car	大型车辆	外观尺寸较大的乘用车目标
small-truck	小型货车	小型货运车辆目标
big-truck	大型货车	大型货运车辆目标
oil-truck	油罐车	具有特殊罐体结构的专用货运车辆

这种基于视觉特征的车型划分,旨在为系统提供高效、轻量化的前端数据感知基座。需要指出的是,该视觉分类方案侧重于交通状态的宏观统计,其功能定位与收费公路涉及轴重、物理吨位等复杂准则的收费车型判定标准存在本质区别。在实际推理过程中,系统会对模型输出的候选检测框进行置信度过滤,并将保留的有效类别编号自动转换为论文表述中的中文车辆类型名称(如将 oil-truck 映射为“油罐车”)。此外,为了保持实验数据与算法输出的一致性与可追溯性,在后续第 3 章的实验图表(如 PR 曲线和混淆矩阵)中仍保留原始英文标签,正文分析时统一依照表 2 的中文表述进行对应说明。

4. 实验结果与系统应用分析

为了验证本文所构建的 CBAM-WIoU-YOLOv10 车辆类型识别模型在高速公路车辆识别任务中的有效性,本章基于车辆类型识别数据集开展模型训练与验证实验,并结合训练过程曲线、模型性能指标、PR 曲线、混淆矩阵以及验证集识别效果图,对模型检测性能和系统应用可行性进行分析。

本章实验分析主要围绕两个方面展开:一是从模型训练和识别性能角度,分析 CBAM-WIoU-YOLOv10 在车辆类型识别任务中的检测效果;二是结合第 1 章设计的云-边-端系统架构,分析模型识别结果在边侧车辆识别和云侧结果应用中的支撑作用。

4.1. 实验环境与数据设置

4.1.1. 实验环境与参数设置

本文实验任务属于目标检测任务,模型需要同时完成车辆目标定位和车辆类型识别。实验基于第 2 章构建的 CBAM-WIoU-YOLOv10 车辆类型识别模型进行训练,并以原始 YOLOv10 模型作为对比模型,用于分析本文改进模型在车辆识别任务中的表现。实验环境与主要参数设置如表 3 所示。

Table 3. Experimental environment and parameter settings
表 3. 实验环境与参数设置表

项目	设置
操作系统	Windows 11
GPU	NVIDIA GeForce RTX 3060
Python 版本	Python 3.9
深度学习框架	PyTorch (基于 CUDA 12.6)
模型框架	YOLOv10
改进模型	CBAM-WIoU-YOLOv10
基础模型	YOLOv10m
输入图像尺寸	640 × 640
训练轮数	150
Batch size	8
类别数	6
任务类型	目标检测
评价指标	Precision、Recall、mAP、PR 曲线、混淆矩阵

数据集共包含 6 类目标：小型车辆(tiny-car)、中型车辆(mid-car)、大型车辆(big-car)、小型货车(small-truck)、大型货车(big-truck)、油罐车(oil-truck)。模型性能评价体系主要采用 Precision(精确率)、Recall(召回率)、mAP@0.5、mAP@0.5:0.95、PR 曲线和混淆矩阵进行多维度评估。

4.1.2. 数据集划分与类别分布

本文实验数据集共包含 6 类车辆目标，分别为小型车辆(tiny-car)、中型车辆(mid-car)、大型车辆(big-car)、小型货车(small-truck)、大型货车(big-truck)、油罐车(oil-truck)。为了保证模型训练与性能验证的可靠性，本文对数据集进行了统一整理，并按照约 7:2:1 的比例划分为训练集、验证集和测试集。其中，训练集用于模型参数学习，验证集用于训练过程中的性能评估和最优权重选择，测试集用于最终模型性能验证。数据集划分情况如表 4 所示。

Table 4. Dataset division
表 4. 数据集划分情况表

数据集类型	图像数量/张	目标实例数/个	用途
训练集	5068	8567	模型训练与参数更新
验证集	1448	2440	模型验证与权重选择
测试集	724	1232	最终性能测试
合计	7240	12,239	模型训练与验证

各车辆类别目标实例分布如表 5 所示。

由表 5 可知，数据集中小型车辆、中型车辆和小型货车数量相对较多，油罐车样本数量相对较少，整体呈现一定类别不均衡特征。该分布与高速公路实际交通场景较为接近，即常见乘用车和普通货车车辆数量较多，而油罐车等特殊车辆出现频次相对较低。针对上述情况，本文在模型训练过程中采用随机

打乱、图像缩放、色彩扰动和 Mosaic 数据增强等方式提升样本多样性，从而增强模型对不同车辆类型和复杂场景的适应能力。

Table 5. Distribution of vehicle categories in the dataset
表 5. 数据集车辆类别分布表

原始标签	论文表述	目标实例数	占比
tiny-car	小型车辆	3528	28.83
mid-car	中型车辆	2764	22.58
big-car	大型车辆	1986	16.23
small-truck	小型货车	2153	17.59
big-truck	大型货车	1276	10.43
oil-truck	油罐车	532	4.35
合计	全部类别	12,239	100.00

4.2. 模型训练过程分析

模型训练损失与评估曲线如图 3 所示。




Figure 3. Model training loss and evaluation curves
图 3. 模型训练损失与评估曲线图

由图可知，在训练初期，边界框回归损失、分类损失和 DFL 损失下降较快，说明模型能够在较短轮次内学习到车辆目标的基本特征。随着训练轮次增加，各项损失整体呈下降趋势，并在中后期逐渐趋于稳定。与此同时，Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 等验证指标整体呈上升趋势，表明模型对 6 类车辆目标的检测能力逐步增强。虽然训练过程中部分指标存在一定波动，但整体收敛趋势较为明显，说明模型训练过程基本稳定。

4.3. 车辆类型识别性能分析

4.3.1. 不同模型整体性能对比

将原始 YOLOv10m 模型与 CBAM-WIoU-YOLOv10 模型进行对比验证, 结果如表 6 所示。

Table 6. Comparison of vehicle recognition performance of different models

表 6. 不同模型车辆识别性能对比表

模型	Precision/%	Recall/%	mAP@0.5/%	mAP@0.5:0.95/%
YOLOv10m	86.82	83.94	88.21	77.72
CBAM-WIoU-YOLOv10	93.45	89.82	96.35	82.49

由表 6 可知, 与原始 YOLOv10m 模型相比, CBAM-WIoU-YOLOv10 模型在 6 类车辆类型识别任务中取得了更好的整体检测效果。其中, Precision 由 86.82% 提升至 93.45%, Recall 由 83.94% 提升至 89.82%, mAP@0.5 由 88.21% 提升至 96.35%, mAP@0.5:0.95 由 77.72% 提升至 82.49%。实验结果表明, 引入 CBAM 注意力机制和 Wiou 损失函数后, 模型在车辆目标特征提取、漏检控制和边界框定位方面均得到一定改善。

综合来看, CBAM-WIoU-YOLOv10 在保持较高检测精度的同时, 能够较好完成小型车辆、中型车辆、大型车辆、小型货车、大型货车和油罐车等 6 类目标的检测与识别任务。

4.3.2. 消融实验性能对比

Table 7. Performance comparison of ablation experiments

表 7. 消融实验性能对比表

模型	CBAM	WIoU	Precision/%	Recall/%	mAP@0.5/%	mAP@0.5:0.95/%
YOLOv10m	×	×	86.82	83.94	88.21	77.72
YOLOv10m + CBAM	√	×	87.41	84.75	91.65	78.33
YOLOv10m + Wiou	×	√	87.28	84.75	93.65	80.61
CBAM-WIoU-YOLOv10	√	√	93.45	89.82	96.35	82.49

由表 7 可知, 在 YOLOv10m 基础上分别引入 CBAM 注意力机制和 Wiou 损失函数后, 模型检测性能均有不同程度提升。单独引入 CBAM 后, 模型 Precision 由 86.82% 提升至 87.41%, Recall 由 83.94% 提升至 84.75%, mAP@0.5 由 88.21% 提升至 91.65%, mAP@0.5:0.95 由 77.72% 提升至 78.33%, 说明 CBAM 模块能够增强模型对车辆关键特征区域的关注能力, 有助于改善复杂背景下的车辆识别效果。

单独引入 Wiou 后, 模型 Precision 达到 87.28%, Recall 达到 84.75%, mAP@0.5 达到 93.65%, mAP@0.5:0.95 达到 80.61%。相比仅引入 CBAM 的模型, Wiou 在 mAP@0.5 和 mAP@0.5:0.95 指标上提升更明显, 说明 Wiou 损失函数对车辆目标边界框回归具有较好的优化作用。

当 CBAM 与 Wiou 同时引入后, 模型各项指标均达到最优, 其中 Precision 达到 93.45%, Recall 达到 89.82%, mAP@0.5 达到 96.35%, mAP@0.5:0.95 达到 82.49%。这说明 CBAM 和 Wiou 在模型改进中具有一定互补作用: 前者主要增强车辆目标特征表达能力, 后者主要提升边界框定位精度, 二者结合能够进一步提高模型在车辆类型识别任务中的综合性能。

4.3.3. 最优权重验证性能分析

通过使用验证集筛选得到的最优权重 `best.pt`，在独立测试集上进行性能评估，模型 Precision 达到 93.45%，表明误检情况相对较少；Recall 达到 89.82%，说明模型能够识别出大部分车辆目标，但在远距离、小尺度或遮挡场景下仍存在一定漏检情况。在不同 IoU 阈值下，mAP@0.5 达到 96.35%，评价标准更为严格的 mAP@0.5:0.95 达到 82.49%，展现出较好的综合检测与定位能力。

4.3.4. PR 曲线与单类别 AP 表现

PR 曲线如图 4 所示。




Figure 4. PR curves for vehicle type recognition
图 4. 车辆类型识别 PR 曲线图

根据 PR 曲线统计，各类别 AP@0.5 的具体表现如表 8 所示。

Table 8. Results of AP@0.5 for each vehicle category
表 8. 各车辆类型 AP@0.5 结果表

原始标签	论文表述	AP@0.5/%
tiny-car	小型车辆	96.0
mid-car	中型车辆	95.0
big-car	大型车辆	98.4
small-truck	小型货车	97.6
big-truck	大型货车	95.2
oil-truck	油罐车	95.9
all classes	全部类别	96.3

由表 8 可知，模型在 6 类车辆目标上的整体 AP@0.5 表现较好，全部类别 mAP@0.5 达到 96.3%。其

中,大型车辆和小型货车的 AP@0.5 相对较高,分别达到 98.4%和 97.6%;中型车辆和大型货车的 AP@0.5 相对略低,但仍保持在 95%以上。总体而言,CBAM-WIoU-YOLOv10 模型在 6 类车辆目标上的检测表现较为稳定,能够满足车辆类型识别任务的基本需求。

4.3.5. 模型复杂度与推理效率分析

由于本文系统采用云-边-端协同架构,车辆目标检测与类型识别任务主要部署在边侧设备完成,因此模型不仅需要具备较高检测精度,还应具有较好的推理效率。为了分析改进模型在边侧部署中的可行性,本文对 YOLOv10m 和 CBAM-WIoU-YOLOv10 的参数量、模型大小、计算量和推理速度进行了对比,结果如表 9 所示。

Table 9. Comparison of complexity and inference efficiency of different models
表 9. 不同模型复杂度与推理效率对比表

模型	参数量/M	模型大小/MB	计算量/GFLOPs	单张推理时间/ms	FPS
YOLOv10m	15.40	31.8	59.1	12.1	82.6
CBAM-WIoU-YOLOv10	15.82	32.6	60.4	12.8	78.1

由表 9 可知,与原始 YOLOv10m 模型相比,CBAM-WIoU-YOLOv10 模型的参数量由 15.40 M 增加至 15.82 M,模型大小由 31.8 MB 增加至 32.6 MB,计算量由 59.1GFLOPs 增加至 60.4 GFLOPs。由于引入了 CBAM 注意力模块,改进模型的单张推理时间由 12.1 ms 增加至 12.8 ms,FPS 由 82.6 降至 78.1。虽然改进模型的计算开销略有增加,但整体增幅较小,仍能保持较高的推理速度。结合表 6 和表 7 的检测性能结果可知,CBAM-WIoU-YOLOv10 在增加少量参数量和推理时间的情况下,提高了车辆识别精度和边界框定位能力,在检测精度与推理效率之间取得了较好平衡,具备进一步开展边缘设备部署验证的基础。

需要说明的是,本文推理速度测试基于实验环境中的 NVIDIA GeForce RTX 3060 GPU 完成。在实际边缘计算设备中,模型推理速度还会受到硬件算力、视频输入分辨率、并发路数和模型部署框架等因素影响。

4.4. 车辆识别结果与系统应用分析

4.4.1. 视觉检测效果

选取验证集图像进行可视化测试(如图 5 所示)。




Figure 5. Visual detection results of multi-target vehicles on the validation set

图 5. 验证集多目标车辆可视化检测效果图

结果直观显示，模型能够较准确框选画面内的多目标车辆，并同步输出准确的类别标签与高置信度分数。这表明该模型具备处理复杂交通视频流多目标检测任务的能力，能够为边侧识别模块提供较为可靠的结果判定。

4.4.2. 边侧识别数据输出

在云-边-端系统中，模型部署在边侧设备端推理后，可直接输出轻量化的结构化数据。输出内容包含车辆类别、置信度、坐标、帧编号及时间等核心信息，详见表 10。

Table 10. Output contents of edge-side vehicle recognition results
表 10. 边侧车辆识别结果输出内容表

输出内容	含义	系统用途
车辆类别	模型判断的车辆类型	用于车辆类型统计和结果展示
置信度	模型对识别结果的可信程度	用于筛选低置信度结果
检测框坐标	车辆目标在图像中的位置	用于图像标注和目标定位
图像帧编号	当前识别结果对应的视频帧	用于结果追踪和视频回溯
设备编号	上传结果的边侧设备来源	用于云侧设备管理和数据归属
检测时间	当前车辆识别结果生成时间	用于车辆流量统计和时序分析

这种“边侧处理、云侧汇聚”的机制能够将原始视频转换为车辆类别、置信度、检测时间和设备编号等结构化识别结果后上传，有助于降低原始视频集中传输造成的网络带宽压力，并提高识别结果传输与应用的及时性。

4.4.3. 云侧结果展示与统计应用设计

为进一步说明边侧识别结果在云侧平台中的展示与应用方式，本文根据系统功能需求设计了云侧平台综合展示界面示意图，如图 6 所示。



Figure 6. Schematic of the comprehensive display interface of the cloud-side platform
图 6. 云侧平台综合展示界面示意图

由图 6 可知,根据系统功能需求,所设计的云侧平台主要包括数据概览、车型统计、车流趋势分析、设备状态管理、识别记录查询和异常提醒等功能模块。

在数据概览模块中,平台可展示今日识别车辆总数、在线设备数、今日告警数和数据上传成功率等关键指标,用于反映系统当前运行状态。在统计分析模块中,平台可通过柱状图展示不同车辆类型的识别数量,通过饼图展示车辆类型占比,并通过折线图展示分时段车流量变化趋势。这些可视化结果能够较直观地反映道路车辆组成结构和交通流变化情况。

在设备管理模块中,平台可根据设备编号、部署位置、在线状态、今日识别数量和最近上传时间等信息,对不同边侧识别节点进行统一管理。当某一边侧设备出现离线、上传延迟或数据波动异常时,系统可通过异常提醒模块进行提示,便于维护人员及时排查问题。

在识别记录模块中,平台可保存车辆类别、置信度、检测时间、来源设备和图像帧编号等信息,为后续识别结果查询、视频回溯和异常数据核验提供依据。

因此,从系统功能设计角度看,所设计的云侧平台能够将边侧模型输出的结构化识别结果用于集中展示、统计分析和设备管理,为后续系统开发与工程部署提供功能参考。

4.4.4. 整体系统可行性讨论

综上实验与分析,CBAM-WIoU-YOLOv10 模型凭借较高的 mAP 和较好的综合检测性能,为交通运行统计分析提供了较可靠的数据支撑。其检测结果能够贯通“端侧视频采集-边侧模型推理-云侧结果汇聚应用”的业务流程,具备在高速公路车辆类型识别场景中进一步部署与应用的可行性。

5. 结论与展望

本文针对高速公路车辆监控场景中车辆类型识别实时性不足、人工统计效率较低以及云端集中处理压力较大的问题,设计了一种基于云边端协同架构的高速公路车辆类型识别系统,并构建了 CBAM-WIoU-YOLOv10 车辆目标检测与类型识别模型。该系统将视频处理与车辆识别任务部署于边侧,仅向云侧传输车辆类别、置信度、检测时间和设备编号等结构化识别结果,为降低原始视频集中上传造成的网络带宽压力提供了可行方案。针对高速公路监控场景中车辆尺度变化明显、背景干扰较强以及部分类别外观相似等问题,本文在 YOLOv10m 基础上引入 CBAM 注意力机制,以增强车辆关键特征表达能力,并采用 WIoU 损失函数优化边界框回归过程。实验结果表明,改进模型在 6 类车辆目标上的 mAP@0.5 和 mAP@0.5:0.95 分别达到 96.35%和 82.49%,Precision 和 Recall 分别达到 93.45%和 89.82%,推理速度达到 78.1 FPS。结果表明,所提模型在检测精度与推理效率之间取得了较好平衡,具备进一步开展真实边缘设备部署验证的基础。

展望未来,下一步的研究工作将重点引入夜间低照度、雨雪雾霾等恶劣工况下的车辆样本,进一步增强模型在全天候复杂交通环境下的泛化能力与鲁棒性。同时,可结合 TensorRT 等计算图加速框架与模型量化技术,深化真实边缘计算设备中的模型部署与运行优化。此外,依托云侧平台汇聚的大量结构化检测数据,未来还可结合交通流理论,进一步拓展路网承载力评估、异常拥堵预警及宏观车流调度等深层次的智慧交通应用。

致 谢

感谢河北高速公路集团有限公司承德分公司在本研究开展过程中提供的工程应用场景、业务需求及相关试验条件,为车辆类型识别系统的设计与验证提供了重要支撑。感谢哈尔滨工业大学(威海)汽车工程学院在研究方案设计、算法改进及论文撰写过程中给予的指导与帮助。感谢参与现场数据采集、设备调

试、系统测试及结果验证工作的相关技术人员, 为本文研究工作的顺利开展提供了有力保障。同时, 感谢有关专家和同行在研究过程中提出的意见和建议, 为本文研究内容和论文质量的进一步完善提供了帮助。

基金项目

本文受 2025 年河北省省级重大科技支撑计划项目《全量鸿蒙高速公路智慧化应用场景》资助, 项目编号: 252Q0801D。

参考文献

- [1] 林一凡. 基于云边端协同的高速公路智慧服务区全息感知体系分析[J]. 福建交通科技, 2026(4): 83-89.
- [2] 赖树坤, 黄来荣, 王阳生, 等. 高速公路重点地区车辆预警系统设计与实现[J]. 福建交通科技, 2023(2): 73-77.
- [3] 童佳慧, 李越, 李燕君, 等. 边云协同的视频分析任务卸载优化策略[J]. 传感技术学报, 2025, 38(1): 128-134.
- [4] Bharadwaja, D., Reddy, K.S.S., Sriram, M.B.P. and Bavaria, D. (2026) Real-Time Transformer-Based Perception for Intelligent Transportation System. In: *Advances in Intelligent Systems Research*, Atlantis Press International BV, 897-909. https://doi.org/10.2991/978-94-6239-616-6_67
- [5] Liu, L., Song, X., Song, H., Sun, S., Han, X., Akhtar, N., et al. (2024) YOLO-3DMM for Simultaneous Multiple Object Detection and Tracking in Traffic Scenarios. *IEEE Transactions on Intelligent Transportation Systems*, 25, 9467-9481. <https://doi.org/10.1109/tits.2024.3360875>
- [6] 蒋伟进, 孙永霞, 朱昊冉, 等. 边云协同计算下基于 ST-GCN 的监控视频行为识别机制[J]. 南京大学学报(自然科学版), 2022, 58(1): 163-174.
- [7] 孙宏贤, 蒙奕, 王凌礁, 等. 一种云边协同高速公路监测系统的 IACO-LightGBM 任务调度方法[J]. 现代信息科技, 2026, 10(1): 74-80.
- [8] 游昊, 吕文涛, 叶丹, 等. 基于深度学习的车辆检测方法研究进展[J]. 无线电工程, 2025, 55(2): 230-245.
- [9] Ren, S., He, K., Girshick, R. and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39, 1137-1149. <https://doi.org/10.1109/tpami.2016.2577031>
- [10] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/cvpr.2016.91>
- [11] 刘超阳, 曲金帅, 范菁, 等. 基于改进 YOLOv5 算法的车辆目标检测[J]. 云南民族大学学报(自然科学版), 2022, 31(6): 749-754.
- [12] Qiao, Y., Zhao, Y., Jiang, K., Liu, A. and Hu, Y. (2024) Object Detection Algorithm for Unmanned Aerial Vehicle Images Based on YOLOv5. 2024 *IEEE 4th International Conference on Electronic Information Engineering and Computer Science (EIECS)*, Changchun, 24-26 May 2024, 722-729.
- [13] Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., et al. (2024) YOLOv10: Real-Time End-to-End Object Detection. *Advances in Neural Information Processing Systems* 37, Vancouver, 10-15 December 2024, 107984-108011. <https://doi.org/10.52202/079017-3429>
- [14] 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.
- [15] 濮志远, 罗素云. 复杂交通场景下的目标检测方法[J]. 信息与控制, 2025, 54(4): 632-643.
- [16] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. In: Ferrari, V., Hebert, M., Sminchisescu, C. and Weiss, Y., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 3-19. https://doi.org/10.1007/978-3-030-01234-2_1
- [17] 张新宇, 丁胜, 杨治佩. 基于改进注意力机制的交通标志检测算法[J]. 计算机应用, 2022, 42(8): 2378-2385.
- [18] 郑凯东, 戴典珍. 基于改进 YOLOv8 的自动驾驶交通标志检测算法[J]. 信息技术与信息化, 2025(6): 11-14.
- [19] 蒋康, 孙仁云, 李卓霖, 等. 改进 YOLOv8 的轻量化车辆目标检测算法研究[J]. 重庆理工大学学报(自然科学版), 2025, 39(7): 35-42.
- [20] 陈梓延, 王晓龙, 何迪, 等. 基于改进 YOLOv8 的轻量化车辆检测网络[J]. 计算机工程, 2025, 51(5): 314-325.
- [21] 郁强, 王宽, 王海. 一种多尺度 YOLOv3 的道路场景目标检测算法[J]. 江苏大学学报(自然科学版), 2021, 42(6): 628-633.