

# 基于视频云联网技术的隧道车辆检测技术研究

赵廷新<sup>1</sup>, 卢春静<sup>2</sup>, 陈正池<sup>2</sup>, 陈双<sup>3\*</sup>

<sup>1</sup>贵州中南交通科技有限公司, 贵州 贵阳

<sup>2</sup>道坦科技股份有限公司, 贵州 贵阳

<sup>3</sup>贵州理工学院大数据学院, 贵州 贵阳

收稿日期: 2026年5月12日; 录用日期: 2026年6月16日; 发布日期: 2026年6月26日

## 摘要

本文针对高速公路隧道光照复杂、车辆密集及遮挡频繁等环境, 研究了基于视频云联网的隧道车辆检测算法。为提升复杂环境下的检测精度, 在YOLOv5主干网络中嵌入DBB模块, 增强模型对多尺度车辆特征的提取与融合能力。其次, 搭建隧道车辆视频云联网数据集, 涵盖不同时段、不同隧道场景下的车辆样本。实验结果表明, 检测精确度提升0.5个百分点, 达到96.5%。mAP@0.5:0.95指标至80.0%。同时, 模型GPU显存占用量降低36.1%, 由7.56G降至4.83G。本研究为隧道车辆智能监测系统的高效部署提供了可行的技术方案。并验证了该方法在视频云联网环境下的工程应用可行性。

## 关键词

视频云联网, 隧道车辆检测, YOLOv5, DBB

# Research on Tunnel Vehicle Detection Technology Based on Video Cloud Networking Technology

Tingxin Zhao<sup>1</sup>, Chunjing Lu<sup>2</sup>, Zhengchi Chen<sup>2</sup>, Shuang Chen<sup>3\*</sup>

<sup>1</sup>Guizhou Zhongnan Transportation Technology Co., Ltd., Guiyang Guizhou

<sup>2</sup>Daotan Technology Co., Ltd., Guiyang Guizhou

<sup>3</sup>College of Big Data, Guizhou Institute of Technology, Guiyang Guizhou

Received: May 12, 2026; accepted: June 16, 2026; published: June 26, 2026

\*通讯作者。

文章引用: 赵廷新, 卢春静, 陈正池, 陈双. 基于视频云联网技术的隧道车辆检测技术研究[J]. 计算机科学与应用, 2026, 16(6): 165-176. DOI: 10.12677/csa.2026.166217

## Abstract

Aiming at the complex environment of highway tunnels with intricate illumination, dense vehicles and frequent occlusion, this paper studies a tunnel vehicle detection algorithm based on video cloud networking technology. To improve the detection accuracy in complex scenarios, the DBB module is embedded into the backbone network of YOLOv5, which enhances the model's capability of multi-scale vehicle feature extraction and fusion. Secondly, a tunnel vehicle video cloud networking dataset is established, covering vehicle samples collected from different time periods and various tunnel scenarios. Experimental results show that the detection precision is increased by 0.5 percentage points, reaching 96.5%, and the mAP@0.5:0.95 index is improved to 80.0%. Meanwhile, the GPU memory consumption of the model is reduced by 36.1%, decreasing from 7.56G to 4.83G. This study provides a feasible technical solution for the efficient deployment of intelligent tunnel vehicle monitoring systems. The engineering practicability of the proposed method in the video cloud networking scenario is further validated.

## Keywords

Video Cloud Networking, Tunnel Vehicle Detection, YOLOv5, DBB

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

交通运输部统计显示截至 2023 年底我国高速公路总里程达 18.36 万公里。截至 2022 年底全国已建成公路隧道 24850 座总延长 2678.43 万米其中特长隧道 1752 座，总长 795.11 万米[1]。隧道作为高速公路网络中的关键节点，通行状况影响道路的安全性与运行效率。隧道空间封闭、光照骤变及监控画面偏暗等客观条件下，车辆的实时精确监测面临较高的技术挑战。传统分散式视频存储与处理模式在跨路段和跨摄像头中存在明显局限，难以满足隧道交通的监测需求。

随着物联网、5G 通信以及人工智能技术的快速发展，视频云联网技术(Video Cloud Networking, VCN)在智能交通应用逐渐广泛。在交通强国战略的指引下，交通运输部明确提出建设可视、可测、可控、可服务的高速公路运行监测体系，视频云联网已成为行业数字化转型的关键抓手。视频云联网技术正深刻重塑交通运输行业的运行监测与服务模式[2]。其本质是通过云计算、人工智能、边缘计算等前沿技术的深度融合，将分散部署的交通视频监控资源进行统一汇聚、智能分析与协同调度。视频云联网技术为隧道车辆自动化检测提供智能基础设施。基于云端算力开展隧道车辆检测研究，可有效提升隧道数字化监测水平。

## 2. 相关技术与研究现状

### 2.1. 视频云联网技术研究现状

传统视联网依赖端侧采集和云端处理的集中式架构，随着 8K 超高清视频普及和实时交互需求激增，集中式架构在算力成本、传输带宽、隐私安全等方面的瓶颈日益凸显[3]。构建“云边端”一体化算力网络，通过动态调度算法根据任务需求自动分配算力资源，实现从数据上云分析到模型下沉推理的彻底转变。

国内多地启动或完成省级路网运行监测、干线公路网管控相关工程建设[4]。打造交通综合视频汇聚、态势推演及指挥调度系统,构建统一化的视频云平台与“一张图”可视化展示架构。在实际工程应用中,所构建的云视频监控系统已实现规模化部署。视频云平台实现对国省道、高速公路监控资源的集约化管理,接入数百路至数千路不等的视频监控点位。配套建成多功能交通调查站,覆盖数千公里公路路段,实现交通量统计、车牌识别与视频监控的一体化融合,数据融合精度可达 90%。经统计,部分系统日均接入云端监控数据量超 6100 万条,部署 4262 路视频 AI 分析节点。数据表明,该系统通过智能事件识别与自动报警机制,将事故处置时效较人工接警模式平均缩短 9 分钟,事件发现率显著提升 27.97%。

## 2.2. 隧道车辆检测研究现状

在隧道车辆目标检测领域,国内研究针对复杂环境不断优化检测性能。研究显示采用人工定义的 ROI 区域与形态学预处理手段去除车道线等结构性干扰[5],在部分隧道实拍数据中将检测召回率提升了 10% 以上。包含 5000 帧图像的自建隧道中实拍数据集实验,该方法使车辆检测召回率提升 11% 左右。在深度学习模型环境适应性方面,研究者引入注意力机制、自适应特征权重和动态阈值调节策略。有效缓解极端光照变化和连续遮挡对检测的影响,使模型召回率在模拟多车遮挡场景中提升约 5%。在预处理环节,Pony 边缘检测算法和多尺度特征回归机制提升了边缘稳定性和跨层特征融合能力。在多源数据融合方面,将图像、毫米波雷达与 IMU 数据进行时空对齐。结合卡尔曼滤波和 LSTM 构建三维轨迹预测模型,提高复杂场景下目标连续检测能力[6]。

国外研究主要围绕检测框架创新与多模态感知融合展开。在检测框架方面,一种深度卷积网络引入光照自适应模块。通过跨层连接融合浅层光照细节与深层语义特征,有效应对隧道内光照非线性变化。基于模拟多车密集场景下对阴影遮挡车辆的检测准确率提升约 12%。另有研究将注意力机制与动态阈值策略结合,提升了不同光照与交通密度下的检测稳定性。在多模态融合方面,基于 IoT 架构的多源信息处理框架整合光谱传感器、摄像头与毫米波雷达,实现了高鲁棒性的交通事件监测与准确响应[7]。

## 2.3. 隧道场景环境特点与检测挑战

公路隧道作为一种半封闭的地下交通设施,其运行环境具有显著的独特性,对视频监控与智能检测系统提出了严苛要求[8]。公路隧道内结构单一,背景缺乏丰富纹理。车辆与护栏、标识等固定设施在视觉上易混淆。隧道内昏暗、不规则照明、车辆遮挡导致传统方法准确率下降[9]。常规摄像头在逆光或灰尘环境下易漏检或误判。缺乏丰富的国内隧道数据集,使得模型在复杂环境下的泛化能力和鲁棒性难以保障。

基于视频的隧道智能检测系统面临多重技术挑战。低照度与光照不均匀导致的图像质量退化。复杂背景与目标遮挡导致识别困难、事件检测的高误报率与漏报率。也包括设备在恶劣环境下的可靠性问题[10]。这些挑战相互交织,对视频云联网技术在隧道场景中的落地应用提出了更高的技术要求。目前低光图像增强算法可改善图像质量,峰值信噪比达到 24.69。在注意力机制与特征金字塔网络的引入可提升小目标和遮挡目标检测精度,实测系统检测精度达 94.6%。

## 3. 视频云联网

### 3.1. 视频云联网平台

视频云联网平台是隧道车辆检测系统的核心枢纽,承担视频数据接入、处理、分析及应用全流程管理。如图 1 所示。架构设计适配隧道封闭、环境恶劣等场景特点,满足车辆检测的实时性与可靠性要求。如图 2 所示。采用“云-边-端”协同架构,分为四个层级:

终端采集层为数据入口。由隧道内固定枪机、球机等摄像头组成，负责采集车辆运行视频并完成基础预处理；

边缘处理层部署于隧道就近节点。通过轻量化算力实现视频压缩、关键帧提取等就近处理，降低带宽消耗并保障检测连续性；

云端核心层为算力与管理中心。采用集群架构，支持海量设备并发接入，部署高精度检测算法完成车辆识别、轨迹跟踪等核心任务，并实现资源动态调度；

应用服务层面向管理用户。提供可视化展示、告警预警等服务，支撑隧道交通调度与运维管理。




Figure 1. Video cloud platform  
图 1. 视频云平台

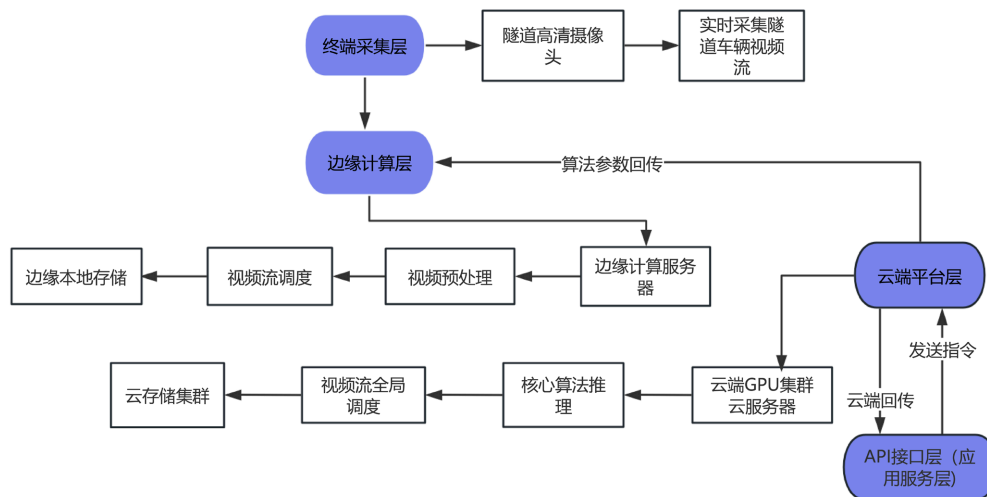


Figure 2. Architecture of the video cloud networking platform  
图 2. 视频云联网平台架构

### 3.2. 隧道视频设备联网

隧道监控视频通常基于 RTSP、GB28181、HLS 等协议完成云端接入，其核心流程包含前端摄像头注册鉴权、云端拉流建立实时媒体流、视频码流转封装解析、解码处理及 AI 模型输入等关键环节。针对隧道场景下的视频特性，接入侧具备低延迟传输、高稳定性运行及高效丢包恢复能力。云端采用多线程或 GPU 加速方式实现视频解码，以适配高并发视频输入需求。解码后的图像帧将进入标准化处理流水线，

依次完成图像缩放、归一化、去雾增强等预处理操作。基于 YOLOv5 模型开展前景车辆检测推理，结合 ByteTrack 算法完成目标 ID 跟踪关联。该流程依托异步队列机制运行，有效规避单路视频阻塞引发的整体延迟升高问题。为满足隧道车辆检测 20 fps~30 fps 的实时性要求，云平台构建完善的资源调度体系，通过 GPU 资源按需调度、显存占用实时监控、任务隔离防护及动态负载均衡等技术手段，保障多路视频并发场景下的推理延迟可控，避免单路视频异常对整体系统造成影响。

## 4. 隧道车辆检测算法设计

### 4.1. 技术总架构

为实现隧道场景下车辆的精准识别与连续轨迹提取，构建基于“检测-跟踪”一体化的技术架构，以 YOLOv5 目标检测算法与 ByteTrack 多目标跟踪算法为核心，串联视频解码、目标筛选、关联匹配、轨迹维护及结果输出全流程。形成闭环式车辆监控处理体系，保障隧道监控中车辆检测的高精度与轨迹跟踪的稳定性。该技术架构以云端视频处理为核心载体，整体遵循分层处理、协同联动的设计原则。视频解码模块作为架构的输入层，负责接收云端接入的隧道监控视频流，通过 GPU 加速解码技术，将连续的视频流解析为标准化的单帧图像数据。如图 3 所示。

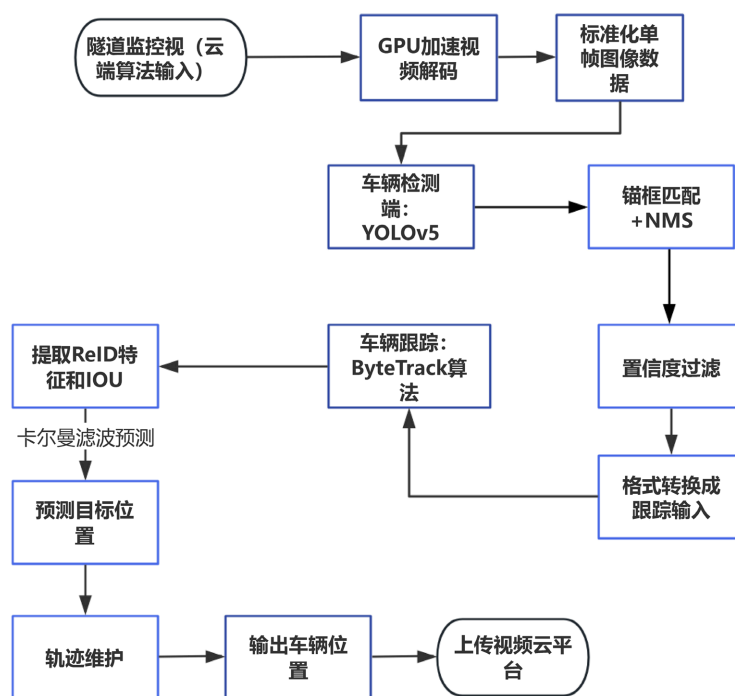


Figure 3. Vehicle detection pipeline  
图 3. 车辆检测流程

### 4.2. 车辆检测算法

YOLOv5 是一种单阶段目标检测算法。具备速度快、精度高、推理稳定等特点，非常适合部署在视频云场景中。其结构主要包括 Backbone、Neck 和 Head 三部分。Backbone 采用 CSPDarknet 提取多尺度特征；Neck 利用 FPN + PAN 结构进行特征融合，增强检测对不同尺度目标的适应性；Detection Head 以 Anchor 为基础预测车辆的类别与边界框。如图 4 所示。

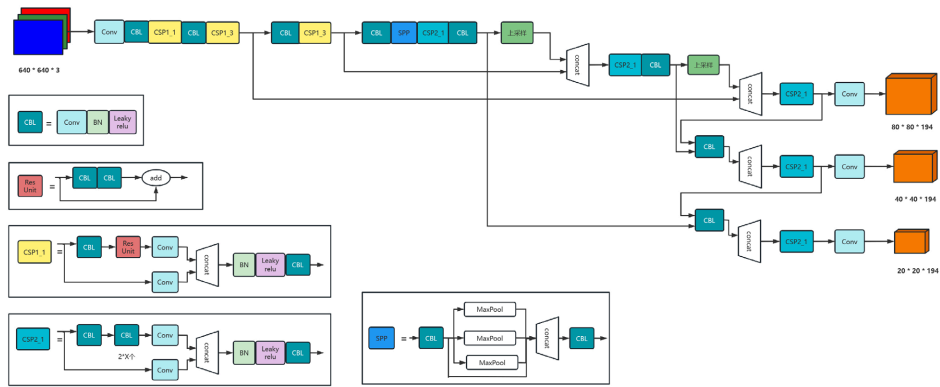


Figure 4. Architecture of YOLOv5  
图 4. YOLOv5 结构

### 4.3. 优化 YOLOv5 模型

#### (1) YOLOv5 在隧道场景中的检测局限性

在隧道交通场景下，YOLOv5 的检测效果面临多重挑战。隧道光照不稳定，出入口及光线不均处易出现过曝。YOLOv5 对边缘与纹理特征依赖度高，易引发漏检或定位偏差。隧道内车辆密集、遮挡频繁，关键部位被遮挡时易出现检测错误与 ID 混淆；此外，车辆高速行驶或视频帧率偏低会造成运动模糊，进一步降低检测框精度与置信度。

#### (2) DBB 重参数化模块优化 YOLOv5

多分支结构块(DBB, Diverse Branch Block)[11]的基本原理是训练时采用复杂多分支结构、推理时等价简化为单卷积[10]。通过在训练阶段将不同尺度卷积、平均池化等多类型分支并行融合，显著增强卷积层的特征表达能力。如图 5 所示。为提升检测头对多尺度目标的特征表达能力，本研究基于可变形卷积块 DBB 对 YOLOv5 的 Detect 模块进行改进。如图 6 所示，DBB-Head 保留原始 P3、P4、P5 三尺度特征图输入结构，将各尺度预测卷积层替换为 DBB 模块。通过差异化的卷积设计，能够有效捕捉复杂光照变化与遮挡场景下的图像特征，增强模型检测能力。

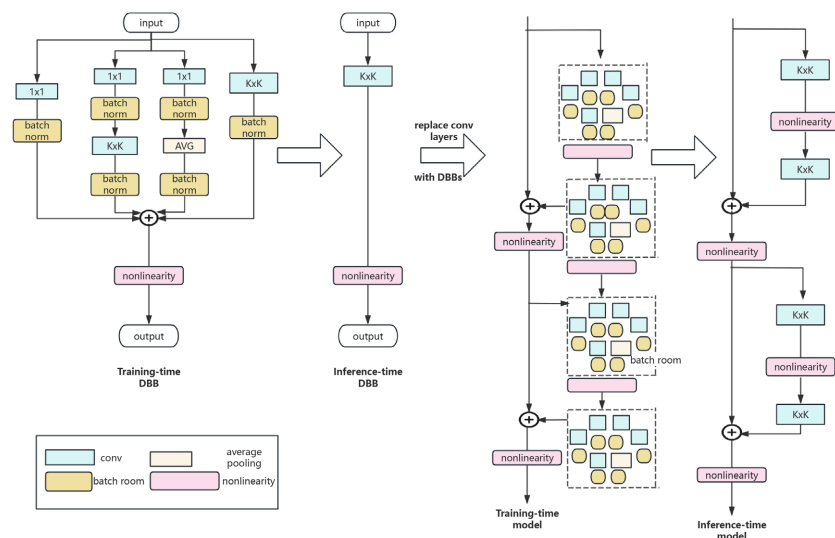


Figure 5. Architecture of DBB  
图 5. DBB 结构

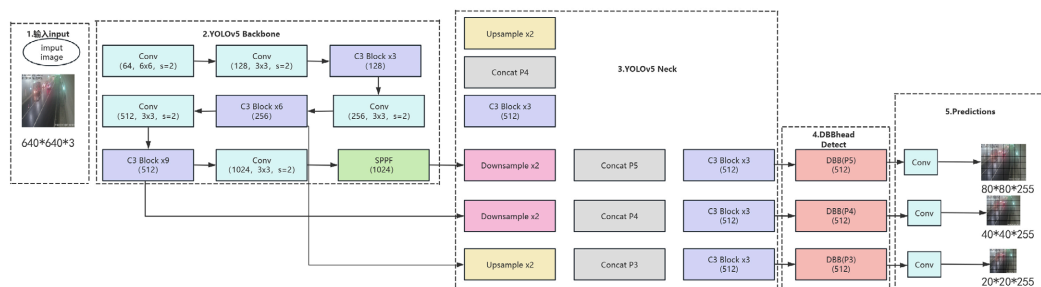


Figure 6. Architecture of YOLOv5-DBB  
图 6. YOLOv5-DBB 结构

#### 4.4. 多目标跟踪算法设计

为了实现车辆的持续跟踪与轨迹输出，本研究在目标检测模块之后引入 ByteTrack 作为多目标跟踪算法。能够实现车辆 ID 连续输出，为后续车流统计与隧道管控提供基础数据支持。ByteTrack 通过对高置信度与低置信度检测结果的分层关联，解决了传统 SORT 类算法在遮挡场景下漂移、丢失轨迹等问题。适合隧道内车辆密集、遮挡频繁的环境。ByteTrack 的主要流程如下：

(1) 高置信度检测框关联

利用 IoU + 运动模型(Kalman Filter)对高置信度检测框进行第一次匹配，生成稳定轨迹。

(2) 低置信度框的辅助关联

未能成功关联的轨迹再与低置信度检测框进行二次匹配，提高遮挡场景中的跟踪连续性。

(3) 轨迹管理算法

对长期未更新的轨迹执行删除，对新出现的目标执行新增。

### 5. 实验与结果分析

#### 5.1. 数据集来源与构成

本研究依托贵州高速公路实际部署的视频云监控系统，采集隧道多视角连续视频流数据。所有视频以 MP4 格式存储于云端，统一分辨率为  $1920 \times 1080$ ，帧率为 25 fps。在视频云处理架构下，为满足车辆检测算法对数据输入的需求，本文对连续视频流进行等间隔抽帧处理，结合人工标注构建车辆检测数据集。表 1 给出了数据集的整体统计信息。共获得标注图像 16115 张，数据对应原始视频总时长为 268 分钟。数据集划分为训练集、验证集和测试集，分别用于模型训练、参数调优和性能评估。

Table 1. Dataset statistics

表 1. 数据集整体统计

指标	数值
总标注图像数	16115 张
训练集	11280 张
验证集	2417 张
测试集	2418 张
抽帧频率	1fps
视频总时长	268 min
分辨率	$1920 \times 1080$
帧率	25fps

表 2 可知数据内容覆盖车辆从隧道入口至出口的完整运行过程，包含弯道路段、不同车流密度工况以及低照度、出入口强光、多车遮挡及灰尘干扰等典型复杂场景，能够有效反映隧道视频监控环境的实际特征。如图 7 所示。

Table 2. Scene distribution of the training set

表 2. 训练集场景分布

场景类型	图像数	占比
正常场景	6446	40.0%
低照度	3223	20.0%
强光(隧道出入口)	2417	15.0%
多车遮挡	3029	18.8%
干扰	1000	6.2%




Figure 7. Vehicle dataset visualization

图 7. 车辆数据展示

为进一步评估模型在极端工况下的性能，本研究针对低照度、强光和多车遮挡这三类典型挑战性场景，构建了独立的测试子集，具体划分情况如表 3 所示。

Table 3. Test subset division

表 3. 测试子集划分

子集名称	描述	图像数
低照度子集	隧道中段光照不足	400
强光子集	出入口强光干扰	300
遮挡子集	多车密集遮挡	350

## 5.2. 评价指标定义

为定量评估隧道车辆检测模型的性能, 本文采用精确率(Precision)、召回率(Recall)、平均精度(AP)与均值平均精度(mAP)四项核心指标, 各指标定义与计算公式如下:

### (1) 精度(Precision)

精确率表征检测器预测为正样本的结果中, 真正正样本的占比, 反映检测结果的准确程度。

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

表达式(1)中:

TP (True Positive, 真正例): 被模型正确检测的正样本数量。

FP (False Positive, 假正例): 被模型错误判定为正样本的负样本数量。

### (2) 召回率(Recall)

召回率表征所有真正正样本中, 被模型成功检测出的比例, 反映模型的漏检情况。

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

表达式(2)中:

FN (False Negative, 假负例): 未被模型检测到的真正正样本数量。

### (3) 平均精度(Average Precision, AP)

平均精度是单类别下, 不同召回率水平对应的精确率平均值, 用于综合衡量模型在该类别上的检测性能。计算时首先按置信度对检测框排序, 逐点计算不同召回率下的精确率, 绘制精确率 - 召回率 (Precision-Recall) 曲线, 曲线下面积即为 AP 值。表达式(3) AP 值越高, 表示检测器在该类别上的性能越好。

$$\text{AP} = \sum_{i=1}^N (R_i - R_{i-1}) \cdot P_i \quad (3)$$

表达式(3)中:

$P_i$  和  $R_i$  分别为第  $i$  个召回点对应的精度与召回率。

### (4) 均值平均精度(mean Average Precision, mAP)

均值平均精度是多类别下所有类别的 AP 值的算术平均值, 用于综合评估模型在全部类别上的平均性能。

$$\text{mAP} = \frac{1}{N_{\text{classes}}} \sum_{i=1}^{N_{\text{classes}}} \text{AP}_i \quad (4)$$

表达式(4)中:

$N_{\text{classes}}$ : 类别的总数,  $\text{AP}_i$ : 第  $i$  个类别的平均精度。

## 5.3. 模型性能对比分析

为验证重参数化分支卷积模块对 YOLOv5 模型检测性能与显存占用的改进效果, 本文以 YOLOv5 为基准模型, 选取 RCSOSA、RepNCSPELAN4 两种常用改进模块作为对比, 设计模型性能对比实验。实验选取精确度(Precision)、召回率(Recall)、mAP@0.5:0.95 作为核心精度评估指标, 以 GPU 显存占用作为模型轻量化评估指标。如下表 4 所示。

**Table 4.** Comparative experimental results  
**表 4.** 对比实验

模型	精确度(Precision)/%	召回率(Recall)/%	mAP@0.5:0.95/%	训练阶段 GPU 显存占用
YOLOv5	96.0	94.2	79.9	7.56G
YOLOv5 + RCSOSA	94.8	91.3	74.2	2.01G
YOLOv5 + RepNCSPELAN4	95.2	91.5	74.5	5.35G
本文方法	96.5	94.2	80.0	4.83G

**Table 5.** Evaluation results on test subsets  
**表 5.** 子集评估结果

模型	低照度 mAP/%	强光 mAP/%	遮挡 mAP/%
YOLOv5	80.5	77.2	78.6
本文方法	81.0	77.6	79.2

对比基线模型(YOLOv5)与两种对比模块(YOLOv5 + RCSOSA、YOLOv5 + RepNCSPELAN4)。单独引入 RCSOSA 或 RepNCSPELAN4 模块后,模型显存占用虽有不同程度下降分别降至 2.01G、5.35G。但精度指标精确度、召回率、mAP@0.5:0.95 均出现明显下滑。其中 RCSOSA 模块的精度损失最为显著,表明这两种改进模块难以兼顾模型的精度与轻量化需求,存在明显性能短板。

本文方法(YOLOv5 + DBB),模型精度实现全面提升。精确度从 96.0%提升至 96.5%,mAP@0.5:0.95 从 79.9%提升至 80.0%,召回率保持与基线模型一致的 94.2%,未损失对目标的覆盖能力。同时,GPU 显存占用从基线的 7.56G 降至 4.83G,相比基线降低 36.1%,实现了精度提升与轻量化的双重突破。

表 5 结果分析在典型复杂场景下,改进模型整体性能均优于基准 YOLOv5 模型。在低照度与多车遮挡场景中,模型 mAP 分别提升了 0.5%和 0.6%,说明所提出的优化方法在弱光及目标重叠情况下具有更好的特征表达能力。在出入口强光场景下,由于存在局部过曝现象,模型性能整体较低,但改进模型仍取得了 0.4%的提升。综合来看,本文方法在隧道复杂环境中表现出更好的稳定性与鲁棒性。

#### 5.4. 可视化检测效果

为了更加直观地展示改进模型的实际检测表现,从测试集中选取了典型场景的图像样例,并在图 8 中给出了与原始 YOLOv5 的可视化对比结果。可以观察到,本文改进模型在车辆边界框拟合方面明显优于原始模型,其检测框能够更加贴合车辆真实轮廓,有效避免了原模型中常见的框偏移、框过大或过小等问题,目标定位精度得到显著提升。



**Figure 8.** Comparison of detection bounding boxes  
**图 8.** 检测框对比

在车辆重叠频繁或存在遮挡的复杂场景中,改进模型仍能稳定区分相邻车辆,实现更加准确地检测。在车辆密集跟车情况下,改进模型保持了更好的框分离能力,减少了误检与漏检现象。如图 9 所示。

此外,在隧道出入口等光照急剧变化的典型高难度场景下,原始 YOLOv5 的检测结果容易出现波动,而改进模型在这些场景中表现更加稳健,能够维持稳定且可靠的检测质量。如图 10 所示。这充分说明加入 DBB 结构后,模型对光照扰动及复杂背景的鲁棒性得到有效增强。



Figure 9. Comparison under dense traffic conditions  
图 9. 车辆密集对比



Figure 10. Comparison under different illumination conditions  
图 10. 光照变化对比

### 5.5. 云联网环境下的模型部署与系统级性能分析

在视频云联网场景中,车辆检测模型通常采用云端集中式部署架构,其运行阶段的 GPU 资源开销直接影响单节点视频并发处理能力及系统整体吞吐性能。因此,对模型资源消耗与部署性能进行系统分析具有实际工程意义。

本文借助 GPU 运行状态监测工具,统计模型推理阶段的显存占用情况。实验结果表明,原始 YOLOv5 模型与本文改进模型推理显存占用分别为 1839MiB 和 1835MiB,二者相差仅 0.2%,资源消耗水平基本持平,说明本文优化方案并未引入显著额外显存开销。

基于 RTX 4090 (24GB 显存)云端 GPU 环境,在车辆检测推理过程中,单路视频流显存占用约为 1.8 GB。由此可估算单卡最大理论并发能力约为 13 路视频流。在该资源约束条件下,本文改进模型与原始 YOLOv5 模型显存占用基本一致。从系统部署角度来看,该并发能力能够满足视频云联网场景下多路视频流的实时接入与检测需求,并支持通过多 GPU 节点横向扩展以提升系统整体处理能力。

在实际应用中,系统通过增加 GPU 节点实现算力扩容,在单卡性能稳定的前提下整体处理能力可近似线性增长。从系统总体拥有成本(TCO)角度来看,该方法在不增加硬件成本的情况下提升了单位算力利用效率,实现了性能与资源消耗的平衡。因此,本文改进模型在不增加显存开销的前提下,实现了检测

性能提升, 并保持了系统级并发能力与部署成本不变。

## 6. 结论

本研究围绕基于视频云联网技术的隧道车辆检测这一应用场景, 针对隧道内部光照复杂、车辆密集度高等问题, 对 YOLOv5 模型进行了结构优化, 并在贵州省高速公路视频云平台的真实数据上进行了验证。研究结论如下:

(1) 构建了适用于隧道场景的视频云联网检测框架, 实现多路视频流的云端集中接入与统一处理, 满足系统实时性与资源调度需求。

(2) 提出基于 DBB 结构的 YOLOv5 改进模型, 有效提升复杂隧道环境下的目标检测精度与鲁棒性。

(3) 在真实数据与平台环境中验证表明, 改进模型在精度与实时性之间取得良好平衡。

(4) 基于 GPU 云端部署分析, 模型在显存开销基本不变的情况下具备稳定单卡并发能力, 可支持多路视频流实时检测, 并通过 GPU 节点扩展实现系统处理能力线性增长。

## 参考文献

- [1] 交通运输部. 2023 年交通运输行业发展统计公报[EB/OL]. 2024-06-18. [https://xxgk.mot.gov.cn/2020/jigou/zhghs/202406/t20240614\\_4142419.html](https://xxgk.mot.gov.cn/2020/jigou/zhghs/202406/t20240614_4142419.html), 2025-05-08.
- [2] 李勇. 四川高速公路视频云联网方案优化设计[J]. 中国交通信息化, 2024(10): 96-99.
- [3] 乔昊昕. 基于云边一体的视频汇聚平台技术研究[J]. 新潮电子, 2025(20): 94-96.
- [4] 刘伯海. 福建省高速公路视频云联网方案[J]. 中国交通信息化, 2023, 278(1): 105-107.
- [5] Liao, J.W., Jiang, S.Y., Chen, M.H., et al. (2025) SAM-YOLO: An Improved Small Object Detection Model for Vehicle Detection. *The European Journal on Artificial Intelligence*, **38**, 279-295. <https://doi.org/10.1177/30504554251319452>
- [6] Yang, L., Wang, Y., Liu, L., Wang, P. and Zhang, Y. (2022) Center Prediction Loss for Re-Identification. *Pattern Recognition*, **132**, Article 108949. <https://doi.org/10.1016/j.patcog.2022.108949>
- [7] Ghanem, S., Kanungo, P., Panda, G., Satapathy, S.C. and Sharma, R. (2021) Lane Detection under Artificial Colored Light in Tunnels and on Highways: An IoT-Based Framework for Smart City Infrastructure. *Complex & Intelligent Systems*, **7**, 3127-3141.
- [8] 徐黎文. 隧道车辆智能检测与交通状态评估研究[D]: [硕士学位论文]. 郑州: 郑州轻工业大学, 2025.
- [9] 薛春明. 隧道智能检测系统软件系统设计与研究[J]. 山西交通科技, 2023(4): 121-124.
- [10] An, H., Fan, Y., Jiao, Z. and Liu, M. (2025) Research on Improved Bridge Surface Disease Detection Algorithm Based on YOLOv7-Tiny-DBB. *Applied Sciences*, **15**, Article 3626. <https://doi.org/10.3390/app15073626>
- [11] Ding, X., Zhang, X., Han, J. and Ding, G. (2021) Diverse Branch Block: Building a Convolution as an Inception-Like Unit. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 10881-10890. <https://doi.org/10.1109/cvpr46437.2021.01074>