

激视融合与大模型驱动的行駛车辆三维超限检测方法

宁茂财, 赵作鹏, 李晓雨

(中国矿业大学 计算机科学与技术学院, 江苏 徐州 221116)

摘要: 针对传统车辆超限检测方法效率低、环境适应性不佳的问题, 为实现车辆长、宽、高及车牌信息的精准实时测量与超限判定, 提出一种激视融合与 DeepSeek 大模型驱动的行駛车辆三维超限检测方法。该方法通过激光雷达与可见光摄像头的协同感知, 设计多传感器协同框架: 横向与纵向布置的 3 个激光雷达, 经点云滤波与几何计算提取车辆三维尺寸; 采用改进的 YOLOv10-CBAM 模型与 LPRNet 算法实现高精度车牌识别; 融合激光与视觉数据生成标准化 JSON 数据包, 并基于若依框架开发可视化平台, 集成了超限告警与 DeepSeek 智能体处罚建议功能。实际道路测试结果表明, 在日均 1 500 辆车流下, 超限识别准确率可达到 98.7%, 尺寸测量误差小于 1.2%, 车牌识别准确率达到 97.24%, 且昼夜鲁棒性强。该方法为智能交通管理提供了一种高精度、多模态融合的技术方案, 显著提升了超限检测的自动化水平与可靠性。

关键词: 激视融合; DeepSeek; 车辆三维超限检测; 注意力机制; 若依框架

DOI: 10.11907/rjdk.251374

扫描二维码阅读全文: 

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-08

LiDAR-Vision Fusion and Large Model-Driven 3D Overlimit Detection Method for Moving Vehicles

NING Maocai, ZHAO Zuopeng, LI Xiaoyu

(School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Traditional vehicle overload detection methods suffer from low efficiency and poor environmental adaptability. To achieve accurate real-time measurement of vehicle length, width, height, and license plate information as well as overload determination, this paper proposes a 3D overlimit detection method for moving vehicles based on LiDAR-vision fusion driven by the DeepSeek large model. Through the synergistic perception of LiDAR and visible-light cameras, a multi-sensor collaboration framework is designed: three LiDAR sensors arranged transversely and longitudinally extract vehicle 3D dimensions via point cloud filtering and geometric calculation; an improved YOLOv10-CBAM model and the LPRNet algorithm are adopted for high-precision license plate recognition; LiDAR and vision data are fused to generate standardized JSON data packets, and a visualization platform is developed based on the Ruoyi framework, integrating overload alerts and penalty suggestion functions powered by the DeepSeek agent. Real-road test results show that under an average daily traffic volume of 1 500 vehicles, the overload recognition accuracy reaches 98.7%, with a dimension measurement error below 1.2% and a license plate recognition accuracy of 97.24%, while exhibiting strong day-night robustness. This method provides a high-precision, multi-modal fusion technical solution for intelligent traffic management, significantly improving the automation level and reliability of overload detection.

Key Words: LiDAR-vision fusion; DeepSeek; 3D overlimit detection of vehicles; attention mechanism; Ruoyi framework

0 引言

车辆长宽高超限检测是交通管理和安全运营中不可

或缺的一环^[1]。随着道路交通流量的不断增长, 车辆超限问题日益凸显, 给道路交通安全和通行效率带来了严峻挑战。超限车辆的存在严重破坏了道路基础设施, 缩短了道路的使用寿命。通过有效的超限检测, 可以及时发现并制

收稿日期: 2025-07-24

作者简介: 宁茂财(2002-), 男, 中国矿业大学计算机科学与技术学院学生, 研究方向为计算机视觉和模式识别; 赵作鹏(1977-), 男, 博士, 中国矿业大学计算机科学与技术学院副教授、硕士生导师, 研究方向为计算机视觉与遥感图像处理; 李晓雨(2003-), 女, 中国矿业大学计算机科学与技术学院学生, 研究方向为机器学习与人工智能应用。本文通讯作者: 宁茂财。

止这类违规行为,保护道路资源。如图1所示,超限车辆极易引发交通事故,威胁道路交通安全。超限车辆往往因为尺寸过大、重量过重而难以控制,增加了事故发生概

率^[2]。因此,深入研究车辆长宽高尺寸超限检测技术,对于提升交通管理水平、保障道路安全与社会经济发展具有十分重要的意义^[3]。



Fig. 1 Hazard diagram of vehicle exceeding the limit

图1 车辆超限危害图

传统的车辆超限检测方法通常依赖于地面传感器、人工检查或固定检测点,因而存在一定的局限性^[4]。例如,人工检查不仅效率低下,而且容易受到人为因素影响;地面传感器受限于环境条件,如雨雪天气、复杂的交通流量等,可能导致检测精度下降。此外,现有检测系统大多数无法实时获取车辆的三维形态数据,难以有效地识别与判断车辆的长度、宽度和高度超限情况。近年来,激光雷达(Light Detection and Ranging, LiDAR)技术为车辆长宽高检测提供了新的解决方案^[5]。激光雷达技术能够在各种复杂环境下稳定工作,尤其是在低能见度、恶劣天气等条件下,具有较强的穿透能力和鲁棒性。因此,应用激光雷达技术可提高车辆长宽高尺寸检测的准确性和可靠性。然而,激光雷达获取的数据与可见光图像的融合仍然面临一些挑战。激光雷达获取的物体信息是基于反射波的距离、速度等物理特性,缺乏对物体外观细节的识别。可见光图像则可能受到光照、角度、遮挡等因素影响,导致识别误差。因此,如何高效地融合激光雷达获取的数据和可见光图像数据,并准确提取出车辆的三维信息,成为当前研究的热点和难点。

为此,本文提出一种基于激光雷达获取的数据与可见光视觉图像融合的车辆长宽高超限检测方法。首先,提出一个多传感器协同工作框架,结合激光雷达的远程探测能力和可见光图像的细节识别优势,获得车辆的三维尺寸、车牌及车型等信息;其次,设计了系统主机和可视化系统,实现了对车辆长宽高超限的精确检测。实验结果表明,该系统在不同环境下均能够有效地识别超限车辆,具有较高的检测精度和鲁棒性。

1 相关工作

传统的非人工车辆尺寸超限检测方法主要依赖于传感器,这些方法通过传感器检测车辆经过时的尺寸信息,并与标准限值进行对比。例如一些施工人员利用超声波传感器、旋转激光传感器在道路上测试不同速度下的车辆尺寸测量精度。尽管该方法可以有效提取车辆的几何特征,但仍存在设备成本高、维护难度大以及对环境变化敏感等问题。随着计算机视觉和图像处理技术的进步,基于视觉图像的车辆长宽高超限检测方法逐渐成为研究热点。王杰^[6]提出一种基于机器视觉的运动车辆长宽高尺寸估测方法,通过单目摄像机标定技术,采用枚举法估计运动车辆速度,最后通过特征角点空间高度与速度的关系估计目标车辆的长宽高尺寸。Dai等^[7]提出一种基于计算机视觉的卡车高度测量方法,首先进行视野校准,其次利用 Binary Large Object (Blob) 检测和 Histogram of Oriented Gradient (HOG) 检测定位视频帧中的卡车区域,最后通过线段检测和 Blob 检测确定卡车的顶部和底部边界进行高度测量。Han等^[8]提出一种基于计算机视觉和视图几何的单目视觉框架,首先进行相机校准,其次进行车辆像素级分割,最后基于视图几何构建车辆的三维边界框,并转换为实际尺寸。Zhang等^[9]开发了一种多目标跟踪和图像校准方法,使用桥墩上的两个摄像头测量车辆长度和位置,并通过预校准获得相机参数。Lu等^[10]提出一种基于视觉的算法用于定义车辆的3D边界框,并确定车辆是否超高。上述方法的优点在于可以避免大量传感器安装的高成本,并且能够适应复杂的交通环境。然而,这些方法仍面临着

图像质量、光照变化以及车速过快等因素的挑战。

在多模态融合和大模型嵌入领域, Alayrac 等^[11]开发了一种视觉语言模型 Flamingo, 能够通过少量标注示例快速适应新任务。Liu 等^[12]通过视觉指令调优开发了一种大规模多模态模型 LLaVA, 旨在通过语言与视觉的结合来理解和完成各种任务。Xiong 等^[13]开发了一个前沿的视觉模型研究平台 OpenGVLab, 推动了视觉基础模型的发展。然而, 以上大模型仍无法融合激光雷达获得的尺寸数据和可见光视觉信息。

2 实施方案

2.1 激光雷达模块

激光雷达(LiDAR)技术的研发可追溯到20世纪60年代, 该技术通过发射激光脉冲并测量这些信号从目标物体反射回来的时间及强度变化, 以确定物体的距离和空间位置等特性^[14]。如图2所示, 一个典型的激光雷达系统主要包含3个组成部分: 负责发出激光脉冲的发射装置(激光信号发射系统)、用于捕捉反射信号的接收设备(激光信号接收系统), 以及处理和解析所收集数据的信号处理单元(信号处理系统)。激光发射器发射激光脉冲, 当激光脉冲接触到被测物体表面后产生反射及散射, 激光接收系统接收到返回的激光脉冲。之后根据激光发射系统发射激光与接收系统接收激光的时间差, 激光雷达的信号处理系统即能够计算被测目标与激光雷达之间的距离。



Fig. 3 Relationship between LiDAR and lane position

图3 激光雷达与车道位置关系

本文中激光雷达获取到的点云数据格式为 (ρ, θ) , 获得的点云数据中必然会存在一些噪声点。如图4所示, 在车辆尺寸测量中发射的激光光束扫描范围为 $0^\circ \sim 180^\circ$, 角度步进为 0.5° 。

激光雷达距离地面的垂直高度为 h , $\rho \sin \theta > h$ 的数据点称为噪声点, 使用条件滤波法将其去除。条件滤波通常是指在信号处理或数据处理领域, 根据设定的条件对数据或信号进行筛选或修改的过程。该方法可用来去除噪声,




Fig. 2 Composition diagram of LiDAR system

图2 激光雷达系统构成图

本文中激光雷达作为传感器, 需要安装在道路门架横杆上使用, 因此激光雷达的重量和体积必须作为设备选型的重要指标, 以确保其稳定性和长期运行的可靠性。综合考虑各类型激光雷达的制造工艺、使用成本以及应用场景等多重因素, 本文选择了北京因泰立科技股份有限公司制造的 ILS-F13 激光雷达作为测量设备。该激光雷达具备适合固定安装、对环境要求宽泛的特点, 并且在性能、可靠性和经济性之间取得了良好平衡, 能够满足本文对高精度车辆信息采集的需求。

本文需要用到3个激光雷达: 两个激光雷达横向安装于门架横杆上, 主要用于对车辆宽高轮廓数据进行检测, 完成对车辆横向断面的垂直扫描; 一个激光雷达纵向安装于门架横杆上, 主要用于对车辆长高轮廓数据进行检测, 完成对车辆纵向断面的垂直扫描。本文在中国江苏省徐州市睢宁县双沟南道路上安装了激光雷达, 激光雷达与车道的相对位置关系如图3所示。





Fig. 4 Mathematical principle diagram for vehicle three-dimensional dimension calculation

图4 车辆三维尺寸计算的数学原理图

提取有用信息。使用条件滤波去除噪声点的算法步骤为：
①读入数据；②创建条件对象；③设定比较算子；④创建条件限定下的滤波器对象；⑤对于 $\rho \sin \theta > h$ 的数据点执行滤波，并保存滤波结果。

激光雷达计算车辆三维尺寸的主要数学原理如图4所示。以中间的激光雷达测量长高为例，激光雷达在 $0 \sim 180^\circ$ 内发射激光射线，得到一系列点云数据。激光雷达距离地面的垂直高度为 h 。以激光雷达为坐标原点建立直角坐标系，对于每一个点云数据点 (ρ, θ) ，按照式(1)和式(2)可以得到每个点直角坐标系下的坐标 (x, y) 。

$$x = \rho \cos \theta \quad (1)$$

$$y = \rho \sin \theta \quad (2)$$

假设车辆的高为 $height$ ，当检测到一系列连续点的 $y < h$ 时，利用式(3)可得到车辆的高。

$$height = h - y \quad (3)$$

假设车辆的长为 $length$ ，对于一系列 $y < h$ 的点，假设第一个点的横坐标为 x_1 ，第二个点的横坐标为 x_2 ，利用式(4)可得到车辆的长。

$$length = x_2 - x_1 \quad (4)$$

同理，对于左右两个激光雷达，假设车辆的宽为 $width$ ，对于一系列 $y < h$ 的点，利用式(3)可得到车辆的高；假设第一个点的横坐标为 x'_1 ，第二个点的横坐标为 x'_2 ，利用公式(5)可得到车辆的宽。

$$width = x'_2 - x'_1 \quad (5)$$

在激光雷达测量范围内，对于车辆行驶过程中的每个位置，都可以计算出一组长、宽、高信息，本文选取其中最大的长、宽、高。

在现场，本文用激光雷达测量了3种不同类型车辆的尺寸计算误差，如表1—表3所示，测量误差都控制在1.2%以内。

Table 1 Length measurement table

表1 长度测量表

	长/mm	测量/mm	误差/%
车一	12 000	1 2100	0.83%
车二	4 800	4 846	0.96%
车三	8 700	8 779	0.91%

Table 2 Width measurement table

表2 宽度测量表

	宽/mm	测量/mm	误差/%
车一	2 500	2 528	1.12
车二	1 800	1 819	1.06
车三	2 400	2 426	1.08

Table 3 Height measurement table

表3 高度测量表

	高/mm	测量/mm	误差/%
车一	3 700	3 743	1.16
车二	1 500	1 516	1.07
车三	2 700	2 731	1.15

2.2 摄像头模块

在现代智能交通系统中，摄像头模块扮演着至关重要的角色。在本文中，摄像头模块不仅承担着获取车辆物理尺寸之外重要信息的任务，而且通过提供车牌号码、车牌颜色及抓拍场景图等关键数据，极大地增强了整个系统的可靠性和精确性。摄像头捕获的信息为超限检测提供了额外的数据层支持，使得系统能够更加全面地评估每辆车的状态。

首先，车牌识别是摄像头模块的一项核心功能。通过先进的图像处理技术，摄像头可以实时、准确地捕捉并识别车牌号码和颜色。这些信息对于建立车辆的身份档案至关重要，因为其允许系统将具体的超限事件与特定车辆关联起来，便于后续的违规处理和管理。此外，车牌信息也为跨部门合作提供了便利，比如与交通管理部门共享数据以加强监管力度。

其次，通过摄像头捕获的车辆信息同样重要。对于不同类型的车辆，其标准尺寸限制各有差异。因此，准确识别车型是判断车辆是否超限的前提条件之一。结合激光雷达测量得到的长宽高数据，系统可以更精确地判定一辆车是否超出规定的尺寸限制。此外，车型识别还有助于提高数据分析的层次感，使得针对不同类型车辆的管理措施更加科学、合理。

最后，抓拍场景图作为另一项重要输出，提供了关于车辆外观及其周围环境的直观证据。这些图像不仅记录了车辆的整体形态，有助于验证激光雷达测量结果的准确性，而且能展示出车辆在道路上的具体位置和行驶状态。例如，在复杂或多变的道路条件下，仅依赖激光雷达可能无法完全捕捉到车辆的实际尺寸变化，而场景图则能弥补这一不足，确保检测结果的可靠性。

如图5所示，本文使用了海康威视的高清抓拍摄像头，型号为iDS-TCV900-HEM。



Fig. 5 Physical image of camera

图5 摄像头实物图

本文在摄像头内部采用基于改进YOLOv10和LPRNet的车牌识别算法进行车牌识别。YOLOv10是一种先进的目标检测算法，可以识别车牌的位置和矩形框^[15]。LPRNet是专为车牌字符识别设计的深度神经网络^[17]。本文在YOLOv10n模型的主干网络末端与颈部网络初端之间

加入了 CBAM (Convolutional Block Attention Module) 注意力机制,使其关注更重要的特征,以提升目标检测的准确率^[16]。CBAM 结构如图 6 所示,包含通道注意力模块和空

间注意力模块。通道注意力模块的目标是增强每个通道的特征表达,空间注意力模块的目标是强调图像中不同位置的重要性。




Fig. 6 CBAM structure
图 6 CBAM 结构

车牌识别流程如图 7 所示。首先使用改进 YOLOv10 的车牌检测网络提取输入图片中的车牌区域,然后将车牌

区域的矩形框输入 LPRNet 网络进行字符提取,并输出最终的车牌号。




Fig. 7 License plate recognition flow
图 7 车牌识别流程

本文从中国城市车牌开源数据集 (Chinese City Parking Dataset, CCPD) 中选取了共计 22 000 张车牌图像,涵盖蓝色牌照和绿色新能源牌照两类,各省份的车牌数据分布较为均衡。数据按照 8:1:1 的比例随机划分为训练集、测试集和验证集。为加快模型训练速度,所有图像被统一裁剪至 640×640 像素。为了增强实验的可靠性,模型共进行了 150 轮训练。以 PyTorch 框架构建车牌检测模型,实验环境及参数配置如表 4 所示。

Table 4 Experimental environment and parameters configuration
表 4 实验环境及参数配置

实验环境	参数配置
操作系统	Windows 11
GPU	NVIDIA GeForce RTX 3090
CPU	i9-12900H
CUDA	12.2
RAM	32.0 GB
编程语言	3.10.9

为综合验证本文算法的优越性,将本文算法与目前主流的车牌识别算法进行对比实验,包括 YOLOv5+LPRNet、YOLOv8+LPRNet 等,实验结果如表 5 所示。从表中可以看出,本文算法虽然预测时间略长,但在准确率上显著高于另外两种算法。

Table 5 Comparison of different algorithms
表 5 不同算法比较

算法	准确率/%	预测时间/ms
YOLOv5+LPRNet	94.67	103.5
YOLOv8+LPRNet	93.83	116.8
本文算法	97.24	135.4

在现场进行了摄像头抓拍场景图的可视化测试,如图 8、图 9 所示。对于有车牌的车辆,无论在白天还是黑夜,摄像头都可以清晰捕获车辆场景图,并提取车辆的车牌信息。而对于没有车牌或者车牌损坏的车辆,抓拍的场景图无法提取出车牌,会显示加载失败。

2.3 数据融合

如图 10 所示,通过激光雷达测量技术可精确获取车辆的长、宽、高尺寸信息,同时利用摄像头抓拍单元捕捉车辆的车牌号码、车型等关键信息。将这两种技术所获得的数据进行深度融合,并打包成一个综合性的数据包发送至云端或交管平台,可以极大地丰富车辆相关信息,从而实现更精准、高效的车辆超限检测。具体来说,激光雷达技术能够对车辆物理尺寸进行准确测量,这对于判断车辆是否超过了道路或桥梁的安全通行限制至关重要。与此同时,摄像头抓拍不仅能清晰记录车牌号码,便于追踪违规车辆,而且能识别车型,为分析不同车型的通行模式及制定相应管理策略提供依据。

由于摄像头抓拍单元获得的是图像数据,因此本文对其进行了 Base64 编码以加入数据包中^[19]。激光雷达和摄像头抓拍单元获得的数据会在控制箱中融合并发送,本文中数据融合后打包形成的数据包格式为 JSON。

JSON (JavaScript Object Notation) 是一种轻量级的数据交换格式,易于阅读和编写,也易于机器解析和生成^[20]。如今互联网 JSON 已成为各种应用程序之间数据交换和通信的主流格式,其以键值对的形式组织数据,支持多种数据类型,包括字符串、数字、布尔值、数组、对象以及 null。



Fig. 8 Scene diagram of vehicles with license plates

图8 有车牌的车辆场景图



Fig. 9 Scene diagram of vehicles without license plates

图9 无车牌的车辆场景图




Fig. 10 Data fusion flow

图10 数据融合流程

在车辆超限检测的场景中,将激光雷达和摄像头获取的信息融合后打包成一个JSON数据包,可以有效地传递和处理多源数据。本文中JSON数据包的字段说明如表6所示。

3 系统测试

为实现车辆超限检测结果的高效展示与管理,本文基于若依框架(RuoYi)开发了一套可视化系统,如图11所示。该系统通过集成激光雷达与摄像头数据,实时显示车辆三维尺寸、车牌信息及超限告警状态。系统界面支持全天监控、历史数据查询及报表生成功能,可为交通管理部门

提供直观的决策支持。

通过点击“查看”选项,可以看到摄像头抓拍单元拍到的现场车辆场景图和车牌图,长宽高尺寸信息颜色若显示为红色,表明该尺寸超限。如图12、图13所示,无论是白天还是黑夜,系统都可以清晰地得到车辆场景图、车牌信息以及车辆长宽高尺寸。

为了顺应AI时代的发展,本文在系统中还调用Deepseek大模型,插入了“运输超限AI智能体”^[21]。点击“处罚建议”选项,智能体可以根据车辆的长宽高尺寸信息给出超限情况和处罚建议等,如图14所示。

本文在江苏省徐州市睢宁县双沟南道路上进行了为期一周的系统测试,日均检测车辆达1500辆以上,超限识

Table 6 Data field description table			
表 6 数据字段说明表			
字段名	名称	类型	说明
carlimit_id	识别码	String	例如 G310_K345代表该数据来自 G310 公路 K345 路段
car_length	车辆长度	uin16t	单位 cm
car_width	车辆宽度	uin16t	单位 cm
car_height	车辆高度	uin16t	单位 cm
car_type_l	车辆车型	uin16t	基本收费车型:0是客一,1是客二,2是客三,3是客四,4是货一,5是货二,6是货三,7是货四,8是货五
car_dir	行驶方向	uin16t	0正向,1反向
road_number	激光雷达检测的车道号	uin16t	1、2、3
car_speed	车速	uin16t	单位:km/h
car_arle	车轴数	uin16t	保留
time	拍照发生时间	String	抓拍相机时间 yyyy-MM-dd HH:mm:ss
camera_ip	摄像头 IP	String	192.168.6.110
car_number	车牌号	String	
car_colour	车牌颜色	String	
car_road	相机抓拍的车道号	String	1、2、3
car_type_c	相机识别车辆类型	String	
car_pic	场景图片名称	String	0_车牌号_ yyyy-MM-dd HH:mm:ss.jpg
image_s	场景图片	String	base64不用指定前缀
car_License	车牌图片名称	String	1_车牌号_ yyyy-MM-dd HH:mm:ss.jpg
image_c	场景图片	String	base64不用指定前缀




Fig. 11 Visualization system diagram
图 11 可视化系统图



Fig. 12 Daytime scene diagram
图 12 白天场景图



Fig. 13 Dark night scene diagram
图 13 黑夜场景图



Fig. 14 Dialogue diagram of intelligent agent
图 14 智能体对话框

别准确率可达98.7%。具体检测数据如表7所示。

Table 7 Detection data table
表 7 检测数量表

车辆	周一	周二	周三	周四	周五	周六	周日
检测车辆	1 891	1 781	1 752	1 906	1 882	1 879	1 362
超限车辆	261	232	235	233	251	163	68

4 结语

本文针对车辆三维超限检测中的技术难点,提出一种基于多源感知融合的创新方法。通过结合激光雷达的高精度三维测量能力与摄像头图像的细节识别优势,构建了多传感器协同工作框架,实现了对车辆长、宽、高及车牌信息的实时精准获取。实验结果表明,本文系统的测量误差可控制在1.2%以内,且在白天、黑夜等不同光照条件下均表现出较强的鲁棒性,验证了该方法的有效性与实用性。

本文的核心贡献包括:①通过激光雷达点云数据与可见光图像的多模态融合,突破了单一传感器的局限性,显著提升了复杂交通环境下的检测精度;②设计了轻量化的JSON数据包结构与可视化管理系统,为交通管理部门提供了直观的决策支持工具;③引入AI智能体进行超限判

定与处罚建议,进一步推动了超限检测的智能化发展。

本文研究为智能交通系统超限检测提供了新的技术路径,并为未来复杂交通环境下的自动化监测系统奠定了基础。然而,本文在极端天气(如暴雨、浓雾)下的传感器性能优化、多目标车辆并行检测效率提升等方面仍有改进空间。未来工作将探索深度学习模型在数据融合中的深度应用,并尝试结合 5G 通信与边缘计算技术,构建更高效的分布式超限监测网络,以期为智能交通系统的自动化监管与道路安全保障提供更全面的技术支持。

参考文献:

- [1] MUKHLISIN I, HARIRI M. Legal study on the oversight of overloaded motor vehicles: efforts to protect road safety and infrastructure[J]. *Istin-bath: Jurnal Hukum*, 2024, 21(2): 55–70.
- [2] ZHANG W. The impact of highway freight overloading on logistics economy and the long-term governance mechanism[J]. *China Logistics & Purchasing*, 2024(20):101–102.
章薇. 公路货运超限对物流经济的影响及长效治理机制研究[J]. *中国物流与采购*, 2024(20):101–102.
- [3] SONG F F. Analysis of the impact of overloading in the “Zhe-Min border” region on transportation economy and countermeasures[J]. *China Storage & Transport*, 2024(9):145–146.
宋菲菲. “浙闽边”超限超载对运输经济的影响及对策浅析[J]. *中国储运*, 2024(9):145–146.
- [4] PORTOSI V, LANEVE D, FALCONI M C, et al. Advances on photonic crystal fiber sensors and applications[J]. *Sensors*, 2019, 19(8): 1892.
- [5] HU S M. Research on spatial reconstruction algorithm based on multi-source image and point cloud data fusion[D]. Changchun: Changchun University of Science and Technology, 2023.
胡仕敏. 基于多源图像与点云数据融合的空间重构算法研究[D]. 长春:长春理工大学, 2023.
- [6] WANG J. Estimation of length, width, and height dimensions of moving vehicles based on machine vision[D]. Hangzhou: Zhejiang Gongshang University, 2015.
王杰. 基于机器视觉运动车辆长宽高尺寸估测[D]. 杭州:浙江工商大学, 2015.
- [7] DAI F, PARK M W, SANDIDGE M, et al. A vision-based method for on-road truck height measurement in proactive prevention of collision with overpasses and tunnels [J]. *Automation in Construction*, 2015, 50: 29–39.
- [8] HAN D, ZHANG C, WANG L, et al. Automatic outer contour detection and quantification of vehicles using monocular vision[J]. *Structural Control and Health Monitoring*, 2024(1): 6692820.
- [9] ZHANG B, ZHOU L, ZHANG J. A methodology for obtaining spatiotemporal information of the vehicles on bridges based on computer vision[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2019, 34 (6) : 471–487.
- [10] LU L, DAI F. Automated visual surveying of vehicle heights to help measure the risk of overheight collisions using deep learning and view geometry[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2023, 38 (2): 194–210.
- [11] ALAYRAC J B, DONAHUE J, LUC P, et al. Flamingo: a visual language model for few-shot learning[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 23716–23736.
- [12] LIU H, LI C, WU Q, et al. Visual instruction tuning[J]. *Advances in Neural Information Processing Systems*, 2023, 36: 34892–34916.
- [13] XIONG Y, LI Z, CHEN Y, et al. Efficient deformable convnets: rethinking dynamic and sparse operator for vision applications [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024: 5652–5661.
- [14] MAINPRICE J, SISBOT E A, JAILLET L, et al. Planning human-aware motions using a sampling-based costmap planner[C]// *2011 IEEE International Conference on Robotics and Automation*, 2011: 5012–5017.
- [15] WANG A, CHEN H, LIU L, et al. YOLOv10: real-time end-to-end object detection [J]. *Advances in Neural Information Processing Systems*, 2024, 37: 107984–108011.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]// *Proceedings of the 15th European Conference on Computer Vision*, 2018: 3–19.
- [17] ZHERZDEV S, GRUZDEV A. LPRNet: license plate recognition via deep neural networks[DB/OL]. <https://arxiv.org/pdf/1806.10447>.
- [18] ZIERIS P, HORSCH J. A leak-resilient dual stack scheme for backward-edge control-flow integrity [C]// *Proceedings of the 2018 on Asia Conference on Computer and Communications Security*, 2018: 369–380.
- [19] WEN S, DANG W. Research on base64 encoding algorithm and PHP implementation [C]// *2018 26th International Conference on Geoinformatics*, 2018: 1–5.
- [20] BOURHIS P, REUTTER J L, SUÁREZ F, et al. JSON: data model, query languages and schema specification [C]// *Proceedings of the 36th ACM SIGMOD-SIGACT-SIGAI Symposium on Principles of Database Systems*, 2017: 123–135.
- [21] LIU A, FENG B, XUE B, et al. DeepSeek-V3 technical report [DB/OL]. <https://arxiv.org/pdf/2412.19437>.

(责任编辑:黄 健)