

交通场景下基于轨迹分析与虚实融合的车辆交通参数提取研究

曾庆刚¹, 徐学卫¹, 李家虎¹, 武建平¹, 王 庆²,
何光明², 李启源³, 田 鸣⁴, 杨 杰⁵

(1. 平顶山天安煤业股份有限公司, 河南 平顶山 467000;

2. 中兴通讯股份有限公司, 广东 深圳 518057;

3. 河南师范大学 体育学院, 河南 新乡 453007; 4. 郑州市公安局, 郑州 451474;

5. 河南省科学院 应用物理研究所有限公司, 郑州 450008)

摘要: 针对道路交通场景中车辆交通参数的精确提取问题进行了研究, 提出了一种基于轨迹分析的交通参数提取方法; 该方法利用道路监控中的云台相机捕捉车辆行驶轨迹, 结合自动化处理和深度分析技术, 实现了车速、流量及密度等核心交通参数的准确评估; 具体方法包括采用先进图像处理技术对监控视频中的车辆进行精确识别和持续跟踪, 基于车辆轨迹信息自动生成满足不同方向交通流量统计需求的检测线; 通过计算车辆移动距离与时间, 获得瞬时速度和平均速度等关键参数, 并利用时间占有率有效估算交通密度; 实验结果表明, 该方法在车流量统计方面具有较高精度, 能够有效克服传统方法中目标误检及中大型车辆遮挡小型车辆等问题; 此外, 该方法具有良好的稳定性和广泛适应性, 能够适应多种复杂道路交通场景; 该技术为交通管理部门提供了一种高效且精准的交通参数提取手段, 有助于更加准确地掌握道路运行状态, 支持科学的交通管理策略制定, 提升道路通行能力和交通安全水平。

关键词: 交通参数; 轨迹分析; 交通管理; 交通流量统计; 智能交通系统

Vehicle Traffic Parameter Extraction Based on Trajectory Analysis and Virtual-Real Fusion in Traffic Scenarios

ZENG Qinggang¹, XU Xuewei¹, LI Jiahui¹, WU Jianping¹, WANG Qing²,
HE Guangming², LI Qiyuan³, TIAN Ming⁴, YANG Jie⁵

(1. Pingdingshan Tianan Coal Mining Co., Ltd., Pingdingshan 467000, China;

2. ZTE Corporation, Shenzhen 518057, China;

3. School of Physical Education, Henan Normal University, Xinxiang 453007, China;

4. Zhengzhou Public Security Bureau, Zhengzhou 451474, China;

5. Institute of Applied Physics Henan Academy of Henan Science, Zhengzhou 450008, China)

Abstract: Research on the accurate extraction of vehicle traffic parameters in road traffic scenarios is conducted. An extraction method for vehicle traffic parameters based on trajectory analysis is proposed. The method uses pan-tilt cameras in road surveillance to capture vehicle trajectories. It combines automated processing with analytical techniques to accurately extract key parameters such as speed, flow, and density. Specifically, the advanced image processing technology is used to precisely detect and continuously track moving vehicles in video frames. Based on trajectory data, direction-specific counting lines are generated automatically to meet the statistical need of traffic flow. Instantaneous and average speeds are calculated

收稿日期:2025-05-25; 修回日期:2025-06-27。

基金项目:国家自然科学基金资助项目(62072053);河南省重点研发项目(241111220300);江西省 03 专项及 5G 项目(20232ABC03A09)。

作者简介:曾庆刚(1974-),男,硕士,正高级工程师。

通讯作者:徐学卫(1972-),男,大学本科,高级工程师。

引用格式:曾庆刚,徐学卫,李家虎,等. 交通场景下基于轨迹分析与虚实融合的车辆交通参数提取研究[J]. 计算机测量与控制, 2025, 33(12):270-277.

by calculating the moving displacement and time of vehicles, and traffic density is estimated through time occupancy. Experimental results show that the method achieves a high accuracy in traffic volume estimation, effectively reducing false detection and handling the occlusion of small vehicles by larger ones. Additionally, the method has good stability and adaptability in various complex road scenarios, and provides an efficient and precise tool for traffic authorities to assess road conditions, support data-driven management strategies, and improve road capacity and safety.

Keywords: traffic parameters; trajectory analysis; traffic management; traffic flow statistics; intelligent transportation system

0 引言

随着全球城市化进程的持续加快, 城市交通需求急剧增长, 城市道路网络承受的压力不断攀升。根据相关统计数据显示, 城市道路拥堵现象日益严重, 交通事故频发且造成的经济损失巨大, 同时尾气排放加剧环境污染, 严重影响城市居民的生活质量和公共安全^[1]。在此背景下, 提升城市交通管理的智能化和科学化水平, 成为实现城市可持续发展和交通安全保障的关键任务^[2]。

交通参数的准确提取作为交通系统监测与管理的核心基础^[3], 涵盖车辆流量、速度、密度等关键指标, 是实现交通状态评估、拥堵预测、信号优化控制及交通安全分析的重要依据^[4]。高质量的交通参数数据不仅支撑传统交通管理决策, 还为智能交通系统 (ITS, intelligent transportation system) 和自动驾驶车辆路径规划等新兴技术提供了坚实的数据基础^[5]。因此, 研究高效、精准的交通参数提取技术, 具有显著的理论价值与广泛的应用前景。

传统的交通参数采集主要依赖于地磁线圈、雷达传感器、红外检测等物理感知设备^[6], 能够实时反馈交通流信息, 但其部署受限于高昂的设备成本、复杂的维护需求及受环境影响较大等缺陷, 难以满足大规模、复杂多变的城市交通环境需求。近年来, 基于视频图像的交通参数提取方法逐渐兴起^[7]。摄像头设备因其安装灵活、覆盖范围广及数据丰富的优势, 在交通监控领域得到广泛应用。然而, 受限于光照变化、天气影响、遮挡现象及摄像机视角限制等因素, 单帧图像分析方法在目标检测与参数估计的准确性和稳定性方面面临较大挑战, 尤其是在高密度、多目标交织的复杂交通场景中, 性能瓶颈愈发突出。

随着计算机视觉技术和目标跟踪算法的快速发展, 基于目标轨迹分析的交通参数提取成为研究热点^[8]。车辆轨迹作为反映车辆运动规律的时空序列数据, 不仅记录了车辆的位置信息, 还包含运动状态、加速度及轨迹变化趋势等丰富信息。通过深入挖掘和分析轨迹数据, 可以有效弥补传统单帧视觉分析的不足, 提升交通参数估计的精度和鲁棒性。此外, 轨迹分析方法能够动态地反映交通流变化趋势^[9], 支持更精细的交通行为建模和

异常事件检测, 为智能交通系统提供更精准的数据支持。

尽管基于轨迹的交通参数提取方法展示了巨大潜力, 但在多目标遮挡、轨迹断裂及复杂动态环境下的连续跟踪仍存在技术难点。同时, 如何有效融合时空信息实现多维度交通参数的准确估计, 也是当前亟需解决的核心问题^[10]。为此, 本研究提出了一种基于轨迹分析的目标参数提取新方法, 通过构建稳定连续的车辆轨迹, 实现对速度、流量、密度等关键交通参数的联合估计, 以提高交通参数提取的准确性和适应性。

本研究的贡献不仅在于提供了一种创新的交通参数提取技术, 更在于其对智能交通系统、自动驾驶车辆路径规划以及交通拥堵分析等领域的潜在应用价值。通过深入分析真实交通场景中车辆的运动轨迹, 本研究能够准确提取车速、流量、密度等关键交通参数, 为交通管理部门提供实时、精确的数据支持, 从而为智能化交通监控技术的发展奠定坚实的基础。

本文的主要创新点如下:

1) 提出一种基于轨迹分析的多参数联合建模框架, 实现车辆速度、交通流量与密度等关键交通参数的协同估计, 有效提升了参数提取结果的时序一致性与整体稳定性。

2) 提出一种方向感知的检测线自适应生成机制, 基于轨迹方向统计分析自动判别上下行车道, 摆脱人工设定依赖, 增强了方法在复杂非规则道路场景下的泛化能力。

3) 构建了融合真实与虚拟 CARLA 场景的验证体系, 涵盖多类型道路结构、天气条件与交通密度级别, 提升了实验验证的多样性与结果的可信度。

1 交通参数提取方法综述

1.1 交通参数提取的重要性与应用背景

交通参数提取作为现代交通管理和规划中的核心环节, 直接影响交通系统的运行效率和安全性。准确获取车辆流量、速度、密度等关键交通参数, 有助于深入理解交通流的时空动态特性, 为交通状态的分析与预测提供科学依据^[11]。这些参数不仅反映了道路交通的基本运行状况, 还能揭示交通拥堵的形成机制及其发展趋势^[12], 从而为交通流量调控、信号灯配时优化等管理策略提供支持。此外, 交通参数的精准提取对于交通安

全评估具有重要作用,可以识别潜在的危險区域和交通事故高发路段^[13],辅助制定针对性的安全防控措施。在智能交通系统和自动驾驶技术快速发展的背景下,实时且高精度的交通参数提取更成为实现智慧交通管理、动态路径规划及交通事件响应的关键基础^[14]。综上,交通参数提取不仅是传统交通管理的基础工具,也是智能交通技术创新的核心驱动力,对提升城市道路通行效率和保障交通安全具有深远的理论和实践意义^[15]。

1.2 交通参数提取的主流方法综述

交通参数的提取方法经历了从传统物理传感器到现代智能视觉分析的转变,形成了多元化的发展格局。传统传感器方法主要依赖地磁线圈、红外检测器、超声波传感器及雷达设备^[16],这些设备能够直接感知车辆的通过和速度信息,提供较为准确的实时交通流量数据。然而,传感器的安装成本高昂,且受限于设备维护、环境影响及空间覆盖范围^[17],难以满足大规模交通监测需求。随着计算机视觉和深度学习技术的发展,基于摄像头的图像和视频分析方法逐渐兴起。通过摄像头捕捉的交通场景,结合目标检测与跟踪算法,能够实现对车辆位置、速度、行驶轨迹等参数的提取^[18]。该方法具有安装灵活、覆盖范围广及信息丰富的优势,适合复杂交通环境的监测。然而,视觉方法在光照变化、遮挡、多目标交互等复杂条件下仍面临精度和鲁棒性的挑战^[19]。此外,近年来基于无线通信技术的交通参数采集方法逐渐兴起^[20],如车联网(V2X, vehicle to everything)技术,通过车辆与基础设施的实时数据交互,实现车辆动态信息的收集与分析。此类方法能够提供丰富的车辆行为数据,但受限于车辆通信设备的普及率及网络覆盖质量。综上,不同技术路径各具优劣,综合利用多源数据融合技术成为提升交通参数提取精度与实时性的有效方向。

1.3 基于轨迹分析的参数提取方法

基于轨迹分析的交通参数提取方法近年来得到广泛关注,成为提升交通状态监测精度的重要手段。该方法依托于车辆行驶轨迹数据,通过时空序列分析精确刻画车辆运动状态和行为特征。轨迹数据来源丰富,包括车辆搭载的GPS定位系统、视频监控中的多目标跟踪结果以及车联网通信采集的行驶信息。通过对轨迹的解析,可以提取车辆速度、加速度、行驶路径变化及停车时长等多维参数,反映车辆动态行为的细粒度特征,有效提升交通流分析的深度和广度^[21]。基于轨迹的分析不仅有助于揭示交通流的微观演化规律,还能支持交通异常检测、事件预测和路径优化等应用。此外,近年来随着机器学习与人工智能技术的发展,轨迹分析逐渐引入深度学习、时序模型和图神经网络等先进算法,实现轨迹数据的自动特征提取与复杂模

式识别,显著提升了参数提取的准确性和自动化水平。基于轨迹分析的交通参数提取在智能交通系统建设、自动驾驶路径规划、城市交通拥堵治理等领域展现出广泛的应用潜力和研究价值^[22],成为推动交通领域技术进步的重要方向。

2 基于轨迹分析的车辆交通参数提取

在现代城市交通管控体系中,交通参数的精确提取是实现智能化交通管理的关键环节。高效、准确的参数获取不仅能够提升道路资源利用效率,更能为行车安全保障提供重要决策依据。然而,传统的基于定点监测的分析方法在应对复杂多变的交通场景时,存在监测范围有限、数据时效性不足等固有缺陷,难以满足现代智能交通系统对实时性和全面性的要求。这一现状凸显了开发动态化、智能化交通分析方法的迫切需求。

为突破传统方法的局限性并提升交通管控效能,本研究创新性地提出了一种车辆运动轨迹分析算法。该算法通过对交通场景中车辆运动轨迹的时空特征进行深度挖掘,实现了对车速、流量、密度等核心交通参数的高精度提取。这些参数不仅为交通管理部门提供了实时、准确的道路状态监测手段,更为交通流量预测、拥堵预警等智能决策系统提供了可靠的数据支撑,从而推动了智能交通监控技术的创新发展。

本研究方法所提取的交通参数具有重要的实践价值。通过实时获取车速、车流量、道路占有率及车辆行进方向等多维信息,道路监管部门能够全面把握交通运行态势,及时制定并调整管控策略以应对突发状况。道路交通场景参数提取如图1所示。

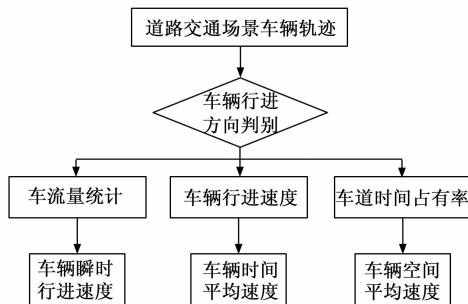


图1 交通参数提取框架图

2.1 车辆行进方向判断

交通参数的提取和异常事件检测依赖于对当前交通场景中目标车辆行进方向的准确识别,为此本研究提出了一种道路上下行方向的自动辨别方法,并在方法设计中考虑了道路监控系统中云台相机的工作特性。云台相机具备多方向旋转拍摄能力,本文选取了4种具有代表性的相机安装位置与拍摄方向组合,并设定了典型的旋转速度范围(5~15°/s)与俯仰角度(-10~30°),以确保相机在车辆通过区域的观测连续性和轨迹稳定性。

该设置不仅提升了目标跟踪的鲁棒性, 也为后续行进方向识别与轨迹特征提取奠定了可靠基础。在虚拟 CARLA 场景中, 相机的参数设置与真实场景保持一致, 以验证方案的通用性与有效性。

为简化处理, 本文选择了 4 种典型的相机安装位置和监控方向的组合视角, 如图 2 所示。在情况一中, 靠近相机的车道方向为车辆方向 A; 而远离相机的车道方向为车辆方向 B; 在情况二中, 靠近相机的车道为车辆方向 B, 远离相机的车道为车辆方向 A; 情况三中, 靠近相机的车道方向为车辆方向 A, 远离相机的车道方向为车辆方向 B; 情况四中, 靠近相机的车道方向为车辆方向 B; 而远离相机的车道方向为车辆方向 A。




图 2 交通场景相机安装情况示意图

本文设定车辆远离相机的方向为车辆上行, 朝向相机的方向为车辆下行。在相机图像坐标系中, 通过捕捉车辆轨迹信息, 我们可以将车辆位置标记为轨迹初始点 (X_{start}, Y_{start}) 和轨迹结束点 (X_{end}, Y_{end}) 。随后, 利用车辆轨迹与图像坐标之间的夹角计算公式计算夹角 θ , 如式 (1) 所示, 实现了对车辆行进方向的判定。

$$\theta = \arctan\left(\frac{Y_{end} - Y_{start}}{X_{end} - X_{start}}\right) \quad (1)$$

当 $0^\circ \leq |\theta| \leq 90^\circ$ 时, 车辆处于上行状态; 当 $90^\circ \leq |\theta| \leq 180^\circ$ 时, 车辆处于下行状态。

2.2 道路车流量计算

道路车流量 G 是指单位时间内通过某道路截面处的车辆数, 是评估道路通行能力与负载水平的重要指标。本研究采用道路截面车流量统计方法来计算车流量, 并依据车辆行进方向划分出上行和下行的检测线, 以适应不同方向的流量统计需求。

合理的检测线位置对于车流量统计的准确性至关重要, 尤其是在基于视频的车流量统计方法中, 检测线位置的设置直接影响到摄像头的安装和视频图像的处理效果。然而, 在复杂的交通场景中, 上行和下行检测线的位置可能会因环境变化而有所不同, 因此, 需要一种灵活的自动检测线设置方法, 以适应各种交通状况。若检测线位置设置不合理, 特别是在匝道区域, 可能会导致驶入或驶离匝道的车辆被遗漏, 进而影响流量分析的准确性。

为解决这一问题, 本研究提出了利用车辆轨迹的起始点和结束点自动生成检测线的方法。轨迹的起点和终点用于构建最小矩形包围区域, 当新轨迹的起点或终点距当前区域中心超过一定阈值时, 将生成新的包围区域, 以标识潜在的匝道或特殊通行路径。在仅有一个起点和一个终点区域的情况下, 取这两个区域中点连线的中点作为检测线的基准点; 在有多个起点或终点区域的情况下, 取这些区域的质心连线作为检测线经过的点。通过这一基准点绘制的横向检测线, 能够灵活适应多种交通场景, 并实现动态调整, 从而在复杂交通环境中显著提升车流量统计的精确度和适应性。

为了计算车流量, 本研究依据上行和下行检测线分别统计车辆通行数量, 并结合车辆轨迹信息, 运用公式 (2) 进行计算:

$$G = \frac{N}{T} \quad (2)$$

其中: G 为道路车流量, N 为单位时间 T 内通过检测线的车辆数量。通过分别统计上行和下行检测线的车辆数量, 本方法能够对双向流量进行精细分析, 以得到更精确的车流量估计。

此外, 为了减少短期波动或偶然事件造成的统计误差, 本研究采用滑动窗口技术对流量数据进行平滑处理, 从而确保车流量结果更加稳定和具有代表性。

2.3 车辆行进速度计算

车辆的行进速度可以分为瞬时行进速度和平均行进速度, 其中车辆的平均速度可以通过记录行驶的总路程和总时间来计算, 包括利用汽车仪表盘、导航设备或专业测速仪器。单个车辆的瞬时行进速度 (km/h) 通过相机视角直接测量, 然后通过相机标定参数来进一步计算。

在本研究中, 车辆行进速度的计算如式 (3) 所示:

$$v = \frac{D \cdot 3600}{t \cdot 1000} \quad (3)$$

式中, D (m) 为车辆在某时间段内的移动距离, t 为车辆通过该段距离所用的时间 (s), 当 T 足够小时, v 可以视为瞬时速度。为确保数据的准确性避免误差, 本研究设定的取样时间间隔为 2 s。

车辆的平均行进速度 V_t (km/h) 定义为该时间段内车辆通过检测线瞬时速度的算术平均值。计算过程如式 (4) 所示:

$$V_t = \frac{1}{N_t} \sum_{j=1}^{N_t} v_j \quad (4)$$

其中: N_t 为时间段内通过检测线的车辆数量, v_j 为第 j 辆车的瞬时速度, $j \in [1, N_t]$ 。

假设检测路段的长度为 S (km), 总共有 N_s 辆车在不同时刻 $(t_1, t_2, \dots, t_{N_s})$ 经过该路段, 每辆车的瞬时速

度为 v_i , 其中 $i \in [1, N_s]$ 。空间平均行进速度 V_s (km/h) 按照式 (5) 计算:

$$V_s = \frac{S \cdot N_s}{\sum_{i=1}^{N_s} \frac{S}{v_i}} \quad (5)$$

2.4 密度和车道占有率的计算

交通密度用于描述道路上车辆的拥挤程度, 它指的是在某一特定时刻, 单位长度路段上所存在的车辆数量。鉴于传统交通密度测量依赖于路段长度数据, 而现代监控设备视野受限, 本研究提出了基于时间占有率的交通密度替代方案。

时间占有率是指目标车辆在设定路段截面所用时间占总观测时长的百分数, 计算公式如式 (6) 所示:

$$\bar{\omega}_t = \frac{\sum_{i=0}^{N_t} t_i}{T_{\text{view}}} \times 100\% \quad (6)$$

其中: 总观测时长为 T , φ_t 为时间占有率 (%), N_t 为该段时间通过车辆总数, t_i 为车辆 i 通过路段所用时长。

根据公式 (6), 能够在有限的视野范围内估算出道路的拥挤程度, 有效地反映了特定时段内道路的交通密度情况。

3 实验

3.1 实验数据

为全面验证本文所提出的基于轨迹分析的交通参数提取方法在不同交通环境下的适用性与有效性, 本研究构建了多源异构的测试验证体系, 通过真实交通场景数据与高保真虚拟仿真数据的有机结合, 实现了对算法性能的系统化评估。这一混合验证策略既保证了实验结果的真实性, 又通过虚拟仿真弥补了真实数据在场景覆盖上的局限性, 为方法验证提供了全面而严谨的实验基础。

真实交通场景数据来源于国内高速公路的智能监控系统, 采集时段涵盖工作日早晚高峰、节假日等典型交通状态。真实数据记录了不同时段、不同天气条件下的车辆运行轨迹。通过对这些视频的逐帧分析, 我们提取了包含车辆位置、速度、加速度等信息的完整轨迹数据, 这些数据不仅反映了常规交通流状态, 还包含了突发拥堵、事故等特殊场景, 为算法在真实环境中的适应性评估提供了丰富的测试样本。此外, 这些标注数据经过团队检验, 确保了轨迹数据的准确性和可靠性, 为后续的参数提取算法提供了可靠的基准数据。

虚拟仿真数据通过 CARLA (Car Learning to Act) 自动驾驶仿真平台与 Unreal Engine (UE) 联合生成, 构建了包含城市道路、高速公路、复杂立交等多样化场景的测试环境。该仿真平台基于物理引擎实现了对复杂交通场景的高保真模拟, 其核心优势主要体现在环境参数精确控制、交通场景灵活配置以及多维度数据采集 3

个方面。在环境参数控制方面, 平台能够精确模拟暴雨、浓雾、夜间等极端条件下的光照、天气和能见度变化, 如图 3 所示, 基于 CARLA 平台对同一场景在晴天、阴雨天、黄昏及雨后等不同天气和光照条件下进行了高保真模拟与可视化展示。在交通场景配置方面, 通过 Python API 可以实现对交通流密度、车辆行为和道路拓扑结构的灵活调整, 从而生成从稀疏到拥堵的不同交通状态。在数据采集维度方面, 平台支持 RGB 相机、深度相机和语义分割相机等多传感器同步采集, 为算法评估提供了全面的测试数据。这些特性不仅有效弥补了真实数据在场景覆盖上的局限性, 更为算法在特定场景下的性能评估提供了系统化的测试方案。



图 3 CARLA 不同环境模拟可视化

在虚拟数据构建过程中, 本研究采用系统化的场景配置方法, 通过多维度参数设置实现了对复杂交通环境的精确模拟。观测视角设置包含高空俯瞰、常规监控高度和车载视角 3 个层次, 全面覆盖了实际交通监控中可能采用的不同观测角度。环境参数配置方面, 研究构建了包含晴天、雨天、雾天和夜间等 4 种典型天气光照条件的测试场景。交通流模拟方面, 通过精确控制车辆生成算法, 实现了从 20~100 辆/公里的密度梯度变化, 并特别设置了车辆异常变道和紧急制动等特殊驾驶行为场景。这种基于参数化控制的精细化数据生成方法, 不仅显著提升了测试场景的覆盖广度, 更为算法性能的系统评估和优化改进提供了可靠的实验依据。

本研究采用严格规范的实验数据采集与处理方法, 确保视频数据的科学性与可靠性。如表 1 所示, 实验数据集由 4 段真实高速公路监控视频和 4 段 CARLA 虚拟仿真视频构成, 共计 8 组测试样本。真实场景视频数据来源于国内高速公路监控系统, 采用 1 920×1 080 分辨率、25 帧/秒的采集标准, 完整记录了不同时段 (早高峰、平峰期、晚高峰) 及天气条件 (晴天、阴天) 下的交通运行状态, 每段视频时长介于 20~40 min, 总时长达 160 min, 共 4 段视频样本; 虚拟场景视频通过 CARLA 仿真平台生成, 每段视频时长统一设置为 10 分钟, 分辨率为 1 920×1 080, 帧率保持 30 帧/秒, 以保证与真实数据采集标准的可比性。

虚拟数据与真实数据在样本数量和总时长上保持 1:1 比例, 增强了验证的客观性与公平性。仿真虚拟

场景覆盖城市道路（2 段）、高速公路（1 段）和立交匝道（1 段），并设置了 4 种典型天气条件（晴天、雨天、雾天、夜间）。交通流密度控制在 20~100 辆/公里范围，覆盖从稀疏流到严重拥堵的多个状态，同时模拟了异常变道、急停等复杂驾驶行为，确保数据多样性与异常覆盖的广度。观测视角设置涵盖高空俯瞰、常规监控视角与车载视角 3 类，提升了测试数据对不同摄像场景的代表性。

所有视频数据均经过严格校验，确保车辆位置、速度等关键参数的标注准确性。所构建数据集具备良好的多样性、代表性与可比性，能够充分支持所提算法在复杂、多变交通场景下的有效性验证与通用性分析。

表 1 实验视频数据详细信息

视频名称	时长/mins	总帧数/万	帧率/FPS	分辨率
01(真实场景)	20	3.0	25	1 280×720
02(真实场景)	22	3.3	25	1 280×720
03(真实场景)	34	5.1	25	1 920×1 080
04(真实场景)	25	3.7	25	1 920×1 080
05(虚拟场景)	10	1.8	30	1 920×1 080
06(虚拟场景)	10	1.8	30	1 920×1 080
07(虚拟场景)	10	1.8	30	1 920×1 080
08(虚拟场景)	10	1.8	30	1 920×1 080

3.2 实验结果分析

在实验阶段，本文针对多种典型交通场景进行了系统性验证，包括城市主干道、交叉口和高速公路等。实验设计充分考虑了实际道路交通状况的评价指标，涵盖车辆行进方向、速度特性、交通流量、交通密度以及车道占有率等核心参数的提取与评估。

通过预设的参考线（蓝色标记上行方向，红色标记下行方向）实现方向分类，解决了混合交通流中方向统计的难题。基于轨迹速度变化率分析，计算瞬时速度与平均速度，尤其关注了急加速和急减速等异常驾驶行为，交通流量的统计通过检测线自动生成，有效避免了传统方法中目标误检和中大型车辆遮挡小型车辆的问题。交通密度的估算则结合时间占有率和车辆空间分布，提高了参数提取的准确性。

为进一步验证所提方法在复杂场景下的稳定性与应用实效，同时评估了算法在不同干扰条件下的鲁棒性表现与实时处理能力。在鲁棒性测试中，通过模拟强遮挡、光照突变及高密度车流等典型交通环境变化，观察算法在轨迹连续性、检测稳定性等方面的波动情况。结果表明，在多类干扰条件下，系统仍能保持较高的提取准确率与稳定性，展现出良好的环境适应能力。在实时性方面，对于 1 080 P 视频可实现平均处理帧率约 21.7 FPS，关键参数提取延迟稳定控制在 135 ms 以内，满足交通监控系统的实时处理需求。

实验结果表明，本文所提出的方法在真实场景与虚拟仿真场景中均表现出较高的精度和良好的适应性，能够有效应对复杂多变的道路交通环境。图 4 展示了交通参数提取的核心处理流程，以真实场景 01 与 02、虚拟场景 05 与 06 为例，系统先提取并识别车辆轨迹，再依据预设的参考线判断车辆行进方向，最后利用轨迹速度变化率和空间分布计算车辆速度、交通密度等核心参数。




图 4 虚实融合交通场景车辆参数提取示意图

在真实场景中，采集的视频数据主要覆盖高速公路主干道等典型通行区域，反映了常规交通流状态下的目标行为特征；而在虚拟场景中，本文基于 CARLA 平台构建了多种具有代表性的高复杂度交通环境，涵盖极端光照条件、车辆高密度拥堵、突发遮挡事件以及道路结构变化等边缘场景，用于模拟现实中难以稳定获取或不易拍摄的特殊交通情况。

通过融合真实与虚拟 CARLA 场景数据，不仅有效弥补了真实数据样本类型受限、边缘场景稀缺等问题，还显著提升了方法验证的全面性和结果的可靠性。同时也进一步验证了所提方法在多种复杂交通条件下的鲁棒性与泛化能力，为其在实际交通监控系统中的推广应用提供了坚实支撑。

以车流量统计为例，表 2 列出了不同场景下的车流量统计结果，结果包括人工计数所得的真实车流量值、算法计算结果以及对应的漏检与误检数量。实验结果表明，本文提出的基于轨迹分析的交通参数提取方法在多数场景中均表现出较高的准确性，车流量统计的整体准确率达到 94.61%，尤其在复杂背景下，如摄像头遮挡等情况下，仍能保持良好的鲁棒性。

此外，通过实验数据的可视化分析发现，交通参数提取的精度受到多种环境因素的显著影响。其中，小型车辆的遮挡问题尤为突出。在实际交通场景中，大型车辆（如货运卡车或公共汽车）由于其庞大的外形特征，往往会在一定时间窗口内完全遮挡后方行驶的小型车辆。这种现象导致检测系统无法持续获取小型车辆的完整轨迹信息，进而造成交通参数提取过程中的数据缺

表 2 车辆交通参数提取结果

视频名称	实际车流量/辆		算法统计结果/辆		漏计或多计数/辆		精度/%		平均精度/%
	上行	下行	上行	下行	上行	下行	上行	下行	
01(真实场景)	135	169	128	160	7	9	94.80	94.70	94.80
02(真场景实)	193	159	181	145	12	14	93.80	91.20	92.50
03(真实场景)	336	304	312	283	24	21	92.90	93.10	93.00
04(真实场景)	579	402	552	370	27	32	95.30	92.00	93.70
05(虚拟场景)	117	132	112	124	5	8	95.70	93.90	94.80
06(虚拟场景)	162	148	161	146	1	2	99.40	98.60	99.00
07(虚拟场景)	143	178	152	168	9	10	93.70	94.40	94.10
08(虚拟场景)	106	145	99	140	7	5	93.40	96.60	95.00

失。特别是在交通流量较大的交叉口或拥堵路段，这种遮挡效应更为明显，直接影响最终参数统计的完整性。

另一个关键影响因素是场景中的误检与漏检现象。在基于视频监控的交通参数提取系统中，车辆检测的准确性是后续所有计算的基础。当系统将非车辆目标（如阴影、道路标志或行人）错误识别为车辆时，会产生误检问题；同时，由于光照条件变化、反光干扰或部分遮挡等原因导致真实车辆未被检测到时，则会出现漏检情况。这些检测误差不仅会降低单帧图像中车辆识别的准确率，还会通过累积效应显著影响车速、流量及密度等关键交通参数的计算精度。

4 结束语

本文介绍了一种基于轨迹分析的车辆交通参数提取方法，能够有效从复杂道路交通场景中获取关键参数。实验结果表明，该方法在车流量统计中实现了平均 94.61% 的精度，表现出较高的准确性与稳定性。同时，本文还分析了影响统计精度的主要因素，包括数据采集误差和数据处理误差，为后续算法优化提供了重要参考。

该方法不仅为交通管理部门提供了实时掌握道路运行状况的有效工具，也为智能交通系统和自动驾驶技术的进一步发展奠定了技术基础。随着相关技术的不断进步和算法的持续完善，基于轨迹分析的交通参数提取将在未来交通管理和规划中发挥更加重要的作用。

针对现有研究的局限性，未来工作将重点从以下几个方向展开。首先，基于深度学习架构开发多目标检测模型，结合注意力机制以增强复杂交通环境下车辆特征的提取能力；其次，采用多模态传感器融合技术，整合红外、雷达等辅助数据源，有效弥补单一视觉信息的不足；最后，设计具备时空上下文感知能力的轨迹关联算法，解决短时遮挡引发的跟踪中断问题。

这些技术改进将显著提升交通参数提取系统在实际应用场景中的鲁棒性与精确度，为构建更加智能、高效和安全的交通系统提供坚实支撑。未来期待与同行展开深入合作，共同推动交通参数提取技术的发展，助力智慧交通生态的建设。

参考文献：

[1] 张敏敏. 智慧理念在城市道路上的应用浅析 [J]. 山西交通科技, 2024 (1): 122 - 125.

[2] CHEN C, LIU B, WAN S, et al. An edge traffic flow detection scheme based on deep learning in an intelligent transportation system [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22 (3): 1840 - 1852.

[3] IYER L S. AI enabled applications towards intelligent transportation [J]. Transportation Engineering, 2021, 5: 100083.

[4] 朱隽洋. 基于数字孪生的交通流量预测方法研究与实现 [D]. 西安: 西安电子科技大学, 2023.

[5] KHAN M A, ECTORS W, BELLEMANS T, et al. UAV-based traffic analysis: a universal guiding framework based on literature survey [J]. Transportation Research Procedia, 2017, 22: 541 - 550.

[6] 陈鑫权. 采用深度学习和无线感知技术的交通参数测量研究 [D]. 杭州: 浙江科技大学, 2024.

[7] FATHY M, SIYAL M Y. A window-based image processing technique for quantitative and qualitative analysis of road traffic parameters [J]. IEEE Transactions on Vehicular Technology, 1998, 47 (4): 1342 - 1349.

[8] TELANG S, CHEL A, NEMADE A, et al. Intelligent transport system for a smart city [M]. Security and Privacy Applications for Smart City Development, Cham: Springer International Publishing, 2020: 171 - 187.

[9] 蒋亚东. 山区公路交通安全设施适应性设计与应用效果评估 [J]. 汽车周刊, 2024 (12): 20 - 22.

[10] 黄德启, 涂亚婷, 张振华, 等. 基于 MLP 与改进 GCN-TD3 的交通信号控制建模与仿真 [J/OL]. 系统仿真学报, 1 - 10 [2024 - 11 - 15]. <https://doi.org/10.16182/j.issn1004731x.joss.24-0523>.

[11] 李任杰, 韩楠, 李庆, 等. 空间数据智能中的轨迹大数据分析: 多源融合与前沿进展 [J]. 无线电工程, 2024, 54 (12): 2735 - 2743.

[12] EKMAN L. On the treatment of flow in traffic safety analysis, -a non-parametric approach applied on vulnerable road users [D]. Sweden: Lund University, 1996.

- [13] 曾海峰. 计算机信息技术在智能交通系统中的应用研究 [J]. 信息与电脑 (理论版), 2024, 36 (14): 35–37.
- [14] YAN Z, ZHENG H, WU C. Multi-agent path finding for cooperative autonomous driving [C] //IEEE International Conference on Robotics and Automation. IEEE International Conference on Robotics and Automation (ICRA), 2024.
- [15] 孙超, 邵源, 张永捷, 等. 广东省数字交通发展规划构思 [J]. 城市交通, 2024, 22 (6): 89–94.
- [16] WANG S, HUANG W, LO H K. Traffic parameters estimation for signalized intersections based on combined shockwave analysis and Bayesian Network [J]. Transportation Research Part C: Emerging Technologies, 2019, 104: 22–37.
- [17] 唐易. 高速公路交通参数获取网络节点布设与传输方法研究 [D]. 北京: 北京交通大学, 2017.
- [18] 杨子枫. 智慧交通中视频交通参数自动提取技术的应用 (上接第 229 页)
- [9] VASWANI A. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017; 30: 5998–6008.
- [10] KOOL W, VAN HOOF H, WELLING M. Attention, learn to solve routing problems! [J]. Stat, 2019, 1050: 7.
- [11] JIN Y, DING Y, PAN X, et al. Pointerformer: Deep reinforced multi-pointer transformer for the traveling salesman problem [C] //Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37 (7): 8132–8140.
- [12] COSTA P R, RHUGGENAATH J, ZHANG Y, et al. Learning 2-opt heuristics for the traveling salesman problem via deep reinforcement learning [C] //Asian Conference on Machine Learning. PMLR, 2020; 465–480.
- [13] YE H, WANG J, CAO Z, et al. DeepACO: neural-enhanced ant systems for combinatorial optimization [C] //Proceedings of the 37th International Conference on Neural Information Processing Systems, 2023; 43706–43728.
- [14] KIM M, CHOI S, KIM H, et al. Ant colony sampling with flownets for combinatorial optimization [J/OL]. Arxiv, 2024-03-11. <https://doi.org/10.48550/arXiv.2403.07041>.
- [15] DEVRIM K M, GOKHAN U M, NAM L S. A reinforcement learning approach to the view planning problem [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017; 6933–6941.
- [16] BRESSON X, LAURENT T. Residual gated graph convnets [J/OL]. Arxiv, 2017-11-20. <https://doi.org/10.48550/arXiv.1711.07553>.
- 研究 [J]. 信息与电脑 (理论版), 2024, 36 (8): 71–73.
- [19] ZHANG B, ZHANG J. A traffic surveillance system for obtaining comprehensive information of the passing vehicles based on instance segmentation [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22 (11): 7040–7055.
- [20] 刘元昊, 张昱, 刘杲朋, 等. 基于雷视一体机的交通流数据采集系统设计 [J]. 计算机测量与控制, 2022, 30 (3): 161–167.
- [21] KHAN M A, ECTORS W, BELLEMANS T, et al. Unmanned aerial vehicle-based traffic analysis: A case study for shockwave identification and flow parameters estimation at signalized intersections [J]. Remote Sensing, 2018, 10 (3): 458.
- [22] 曹向东, 魏云凤, 罗石贵. 基于轨迹数据的高速公路隧道交通特性分析 [J]. 公路, 2024, 69 (10): 233–240.
- [17] BRONSTEIN M M, BRUNA J, LECY, et al. Geometric deep learning: going beyond euclidean data [J]. IEEE Signal Processing Magazine, 2017, 34 (4): 18–42.
- [18] LI P, WANG Y, WANG H, et al. Distance encoding: design provably more powerful neural networks for graph representation learning [J]. Advances in Neural Information Processing Systems, 2020, 33: 4465–4478.
- [19] DWIVEDI V P, BRESSON X. A generalization of transformer networks to graphs [J]. Arxiv Preprint Arxiv: 2012.09699, 2012.
- [20] HE Y, TANG D, ZHANG Y, et al. Grad-pu: Arbitrary-scale point cloud upsampling via gradient descent with learned distance functions [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023; 5354–5363.
- [21] PARISOTTO E, SONG F, RAE J, et al. Stabilizing transformers for reinforcement learning [C] //International Conference on Machine Learning. PMLR, 2020; 7487–7498.
- [22] MEDRESS M F, COOPER F S, FORGIE J W, et al. Speech understanding systems: report of a steering committee [J]. Artificial Intelligence, 1977, 9 (3): 307–316.
- [23] SKINDEROWICZ R. Implementing a GPU-based parallel MAX-MIN ant system [J]. Future Generation Computer Systems, 2020, 106: 277–295.
- [24] SAIDY H N, ILHAM A A. Elitist genetic algorithm and elitist ant colony optimization on resource scheduling in field cloud manufacturing [C] //2022 2nd International Seminar on Machine Learning, Optimization, and Data Science (ISMODE). IEEE, 2022; 403–408.