

中图法分类号: TP391.41 文献标识码: 文章编号: 1006-8961(XXXX)XX-0001-16

论文引用格式: Liu Dian, Yin Na, Zhang Zening, Lv Hongyan, Luo Xubin, Wang Haoxiang. XXXX. Highway parking violation detection by Integrating dual attention feature and spatio-temporal feature. Journal of Image and Graphics, XX(X):0001-0016(刘电, 尹娜, 张泽宁, 吕洪燕, 罗旭彬, 王昊翔. XXXX. 融合双重注意力特征与时空特征的高速公路违停识别. 中国图象图形学报, XX(X):0001-0016)[DOI: 10.11834/jig.250354]

## 融合双重注意力特征与时空特征的高速公路违停识别

刘电<sup>1</sup>, 尹娜<sup>1</sup>, 张泽宁<sup>2</sup>, 吕洪燕<sup>2</sup>, 罗旭彬<sup>2</sup>, 王昊翔<sup>1</sup>

1. 华南理工大学计算机科学与工程学院, 广东广州 510006; 2. 广州国交润万交通信息有限公司, 广东广州 510665

**摘要:** 目的 为提升高速公路交通管理效率与道路安全, 提出一种面向监控视频的违法停车自动识别方法, 以解决车流密集场景中目标遮挡、摄像机透视畸变及夜间光照干扰导致的身份混淆与误判问题。方法 该方法引入了双重注意力特征融合结构, 增强 YOLOv8 提取的多尺度特征的表达能力, 并将生成的外观特征用于后续的轨迹匹配阶段, 从而在保持高效跟踪性能的同时, 有效缓解了目标身份混淆与切换的现象。此外, 还设计了一种基于帧间位移自适应的判别机制来识别违停行为, 有效降低了由视角畸变和边框抖动造成的误判和漏判风险。针对夜间检测的困难, 进一步引入了一种基于时间序列信号分析的报警闪光灯检测技术, 以提升夜间判定的稳定性与准确性, 从而增强整体算法的鲁棒性。结果 鉴于当前尚无公开可用的高速公路违停检测数据集, 结合实际交通管理需求, 自主构建覆盖多场景的专用数据集, 并在此基础上进行实验验证。结果表明, 所提方法能够良好适应不同时间段及复杂条件下的高速公路场景, 违停识别准确率达 94.79%, 召回率达 92.86%, F1 分数为 0.94, 显著优于对比方法。图像处理速度为每秒 32 帧, 满足实时处理需求。结论 提出的融合双重注意力特征与时空特征的方法, 在高速公路违停识别上成效显著, 该研究具备显著的开创性和实践指导意义。

**关键词:** 高速公路; 时空特征; 注意力特征; 违停识别; 双重注意力

## Highway parking violation detection by Integrating dual attention feature and spatio-temporal feature

Liu Dian<sup>1</sup>, Yin Na<sup>1</sup>, Zhang Zening<sup>2</sup>, Lv Hongyan<sup>2</sup>, Luo Xubin<sup>2</sup>, Wang Haoxiang<sup>1</sup>

1. the School of Computer Science and Engineering, South China University of Technology, Guangzhou Guangdong 510006, China; 2.

Guangzhou Runone Traffic Information Co., Ltd., Guangzhou Guangdong 510665, China

**Abstract: Objective** Automatic detection of illegal parking on highways through surveillance video is a crucial task for modern traffic management systems, as it directly affects traffic flow, public safety, and operational efficiency. However, detecting parking violations in highway environments presents substantial challenges due to complex traffic dynamics, varying lighting conditions, and broad surveillance coverage. These challenges include frequent vehicle occlusions in dense traffic, leading to identity confusion and incorrect tracking; significant perspective distortion that causes slow-moving vehicles to be mistakenly identified as parked; and degraded detection performance under low-illumination conditions, where vehicle features become blurred and are prone to false detection due to environmental lighting effects. **Method** To address these problems, the paper proposes a novel highway illegal parking detection algorithm that integrates dual-

收稿日期: 2025-07-24; 修回日期: 2025-12-06

\* 通信作者: 王昊翔, 通信作者, 男, 博士、副教授、硕士生导师, 主要研究方向为机器视觉与模式识别。E-mail: hxwang@scut.edu.cn

基金项目: 广东省省级科技计划项目(2023A1111120018)

Supported by: Guangdong Provincial Science and Technology Project

attention feature fusion and spatiotemporal behavior analysis. The approach first introduces a Dual-Attention Fusion Module (DAFM) to enhance multi-scale feature representations extracted from YOLOv8, which are used as appearance descriptors in a vehicle tracking framework based on BotSORT-ReID. This framework directly leverages YOLOv8's multi-scale feature outputs and enhances them with attention mechanisms in both spatial and channel dimensions. The spatial attention module emphasizes critical regions related to vehicle targets, suppressing background noise, whereas the channel attention mechanism selectively emphasizes discriminative feature channels relevant to object identity. These enhancements significantly improve the robustness and accuracy of vehicle tracking, especially in scenarios involving occlusion, background clutter, or varying viewing angles. **Result** Given that there is currently no publicly available dataset for highway parking violation detection, three dedicated highway datasets were constructed for object detection, vehicle tracking, and parking violation recognition. The datasets consist of 8,532 labeled images for detection, 34,600 frames for tracking, and 77 annotated video sequences (average over 1 minute, covering 98 illegal parking vehicles) for violation recognition. Additionally, they cover diverse conditions including daytime, nighttime, tunnels, and adverse weather such as rain and fog, thereby ensuring comprehensive evaluation across complex highway scenarios. Experimental results on the constructed datasets show that the proposed algorithm consistently outperforms several benchmark methods in terms of precision, recall, and F1-score. Notably, the dual-attention feature extraction improved the identity consistency in vehicle tracking, reducing ID switches and increasing tracking accuracy. The adaptive displacement method demonstrated strong resistance to jitter and perspective artifacts, while the hazard light detection module significantly reduced nighttime false positives and improved robustness under difficult lighting. **Conclusion** Overall, the proposed algorithm presents a unified, efficient, and accurate solution for illegal parking detection on highways. By combining deep learning-based object detection, attention-guided feature fusion, motion pattern recognition, and signal-based validation, this algorithm addresses key limitations in current methods and achieves robust performance across varying highway surveillance conditions. The integration of lightweight attention modules within the YOLOv8 backbone and the design of spatiotemporal behavioral analysis allows for real-time processing while maintaining high accuracy. This makes the system well-suited for deployment in intelligent transportation systems and smart city infrastructure where reliability and adaptability are paramount. The methodology also provides a scalable framework for extending similar detection strategies to other traffic violations or abnormal behaviors in complex road environments.

**Key words:** highway; spatiotemporal feature; attention feature; parking violation detection; dual attention

## 1 相关工作

违法停车是常见的交通违法行为之一,不仅会造成交通拥堵,干扰正常的通行秩序,还可能引发交通事故,增加道路安全风险。尤其在高速公路环境下,违停现象带来的危害更加严重,极大地威胁到公众的生命和财产安全。因此,有效检测高速公路车辆违停行为成为智能交通系统研究中的一个核心问题。早在20世纪90年代,该领域便引起了学术界的广泛关注,相关研究逐步展开,并随着深度学习技术的兴起而进入快速发展阶段。

在车辆违停识别的相关研究中,大多数方法基于图像或视频数据进行分析,部分研究结合传感器信息、全球定位系统(global positioning system, GPS)或轨迹数据等多源信息,以提升检测的准确性。虽

然与视觉数据相比,传感器和GPS等非视觉信息对光照、气候等外部条件的依赖较小,因此在检测稳定性方面具有一定优势,但这些方式往往需要额外的硬件设备或依赖外部系统,因而在实际应用中受到成本和部署条件的限制,难以大规模推广。相较而言,基于视频和图像的检测方法由于监控设备的普遍部署以及图像处理技术的不断成熟,依然是当前最为常见和实用的技术路径。因此,本研究依托高速公路的监控视频与图像数据开展违停行为的识别研究。

### 1.1 基于传统图像处理的违停识别方法

早期的违停识别依赖传统图像处理技术,例如Hassan等人(2012)提出的两阶段识别框架,利用前景分割和自适应跟踪有效识别静止车辆,克服了光照变化和遮挡问题。Wahyono等人(2016)提出了一种基于双背景模型的累积前景差分方法,利用具有

不同学习率的短期与长期高斯混合模型提取前景像素,通过连通域标记形成静态区域,并结合基于规则的筛选与检测跟踪机制,实现对违停车辆的稳健识别。

尽管基于传统图像处理技术的方法验证了计算机视觉在智能交通领域的应用潜力,并为违停检测提供了基础的技术框架,但这些方法仍存在问题,如对特征的过度依赖人工设计、在不同场景下的泛化能力不足以及准确率的限制等。

### 1.2 基于传统机器学习的违停识别方法

随着科技的不断进步,传统图像处理方法在应对复杂场景时逐渐显露出局限性,机器学习凭借其强大的自适应能力和数据处理能力,逐渐成为研究的焦点。后续研究者逐渐将支持向量机(support vector machine, SVM)、随机森林(Random Forest, RF)等传统机器学习算法引入到违法停车检测任务中。例如,(Ketcham等,2019)提出了一种融合SVM与线性回归的检测方法,通过非静态背景差分技术提取车辆的前景区域,随后利用方向梯度直方图(histogram of oriented gradients, HOG)对图像中车辆特征进行提取,最后借助SVM进行分类判断,并通过线性回归进一步优化检测结果。Matsuda等人(2021)将车辆的边界框属性、极值、平均值和方差等统计特征,以及速度与加速度等动态特征作为输入,训练一个基于随机森林的分类模型,结合逻辑回归方法,对路边停车和非道路区域停车的比例进行平衡处理,从而识别违停车辆。

尽管将机器学习方法应用于违停识别在一定程度上提高了算法的鲁棒性和泛化能力,但在面临如小目标检测、车辆遮挡等复杂实际场景时,仍难以克服性能瓶颈,表现仍有待进一步提升。

### 1.3 基于深度学习的违停识别方法

随着数据量的爆炸式增长和任务复杂度的提升,深度学习以其多层非线性变换的强大特征学习能力,开启该领域研究的新篇章。近年来,研究者们将注意力转向利用深度神经网络来提升车辆违停识别的准确性与处理效率。诸多研究尝试将YOLOv3(Peng等,2022)、YOLOv8(Park等,2025)、SSD(Xie等,2017)等高效目标检测算法应用于违停场景以满足实时性的需求。

其中,Hamzah等人(2022)提出基于Faster R-CNN(Ren等,2017)通过四阶段卷积神经网络提取

图像特征,随后由Inception V2(Ioffe等,2016)进行进一步处理,最终通过Softmax分类器与回归模块确定车辆位置及其是否违停的状态。汪琦等人(2024)通过整合多个域的信息,并采用共享子空间度量学习机制,有效解决了跨域车辆特征不一致的问题,提升了车辆重识别精度。余焜等人(2023)通过引入深度卷积网络和残差学习机制,有效提升了夜间低光照条件下车辆图像的质量,增强了车辆特征的可见性,特别是在车型识别中,能够提升车辆的精确识别率。

与此同时,基于Transformer的检测架构,如检测变换器(detection transformer, DETR)及其改进模型也被引入交通场景目标检测和时空特征建模中,利用全局自注意力机制提升了长距离依赖建模能力,在遮挡与拥挤环境下展现出更高的鲁棒性。Chen等人(2025)在轻量化检测框架中引入高效注意力模块,在保证实时性的同时保持较高精度,为资源受限的道路监控设备提供了可行性方案。Zhang等人(2024)通过引入跨帧交互注意力机制,提升了在交通监控中对车辆轨迹和行为的建模能力。徐晗等人(2025)利用Transformer的全局建模能力并引入上下文感知注意力机制,通过自注意力和交叉注意力层融合模板与搜索区域特征,提升复杂场景下的跟踪鲁棒性和准确性。这些研究展示注意力机制在提升检测准确性和适应性方面的潜力。

综上,已有研究在城市道路与普通场景取得进展,但在高速公路场景中仍面临监控范围广、车辆遮挡严重、低照度干扰明显等挑战。尤其是缺乏公开可用的高速公路违停数据集,制约了算法的训练与验证。这些不足凸显了开展针对高速公路违停识别研究的必要性。

针对这些问题,立足于高速公路视频监控场景,提出了一种融合双重注意力机制与时空特征的违停识别方法。主要的创新点包括以下方面:

- 1)提出一种融合空间注意力与通道注意力的双重注意力特征融合模块,在保持轻量化的同时显著提升了多目标跟踪中的身份稳定性;
- 2)设计自适应帧间位移机制,有效解决了透视畸变和检测框抖动导致的误判问题;
- 3)引入基于时序信号分析的危險报警闪光灯检测方法,显著提高了夜间与低照度场景下的违停识别准确性;

同时构建了面向高速公路的车辆违停数据集,并开展了多组对比实验。实验结果表明,该算法在适应不同时间段与天气条件方面展现出良好的鲁棒性与泛化能力。

值得指出的是,当前在公开研究资源中,尚无专门面向高速公路违停行为的标准化数据集。已有研究多聚焦于城市道路或停车场场景,难以覆盖高速公路环境中监控视角远、目标尺度变化大、违停样本稀疏等特点。为此,首次构建了面向高速公路的违停检测专用数据集,包括目标检测、跟踪和违停行为识别等多个任务维度,覆盖昼夜时段、隧道场景以及

多种气象条件,填补了该领域数据资源的空白,该数据集的构建为违停检测任务提供了高质量的数据支撑。

## 2 算法设计

该高速公路车辆违停识别算法的整体流程如图1所示。算法包含两个核心功能模块:基于双重注意力特征融合的轨迹识别模块和基于时空特征的违停判别模块。

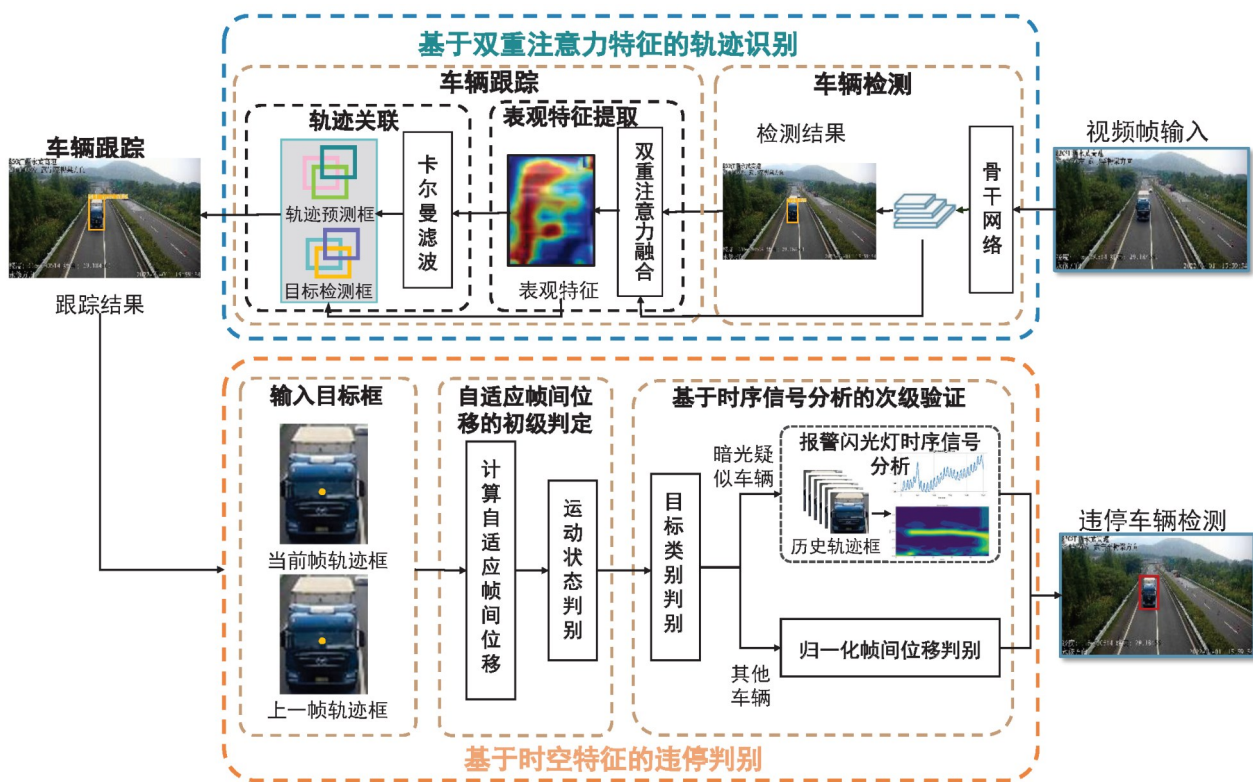


图1 车辆违停识别算法示意图

Fig. 1 Schematic diagram of vehicle illegal parking detection algorithm

轨迹识别模块选用YOLOv8为BotSORT-ReID跟踪算法(Aharon等,2022)的目标检测组件,并将YOLOv8输出的特征通过双重注意力特征融合模块(dual-attention fusion module, DAFM)处理,加强特征的表达能力。融合过程有助于优化BotSORT-ReID跟踪算法中的轨迹关联环节。

违停判别模块包含两个子模块:自适应帧间位移(adaptive inter-frame displacement, AID)的初级判定子模块和基于时序信号分析(Time Series Analy-

sis, TSA)的次级验证子模块。初级验证子模块通过计算每条轨迹的自适应帧间位移来判别其运动状态,如果是低速运动或静止状态,则进入次级验证子模块结合目标类型来判别。次级验证子模块对暗光疑似车辆类型进行报警闪光灯时序信号分析,减低夜间干扰目标误报;对其他类型进行归一化帧间位移判别目标静止状态,提高违停算法在不同场景下的鲁棒性。

## 2.1 基于双重注意力特征的轨迹识别

BotSORT-ReID(Aharon 等, 2022)通过融合外观特征与运动信息,实现多目标追踪的高鲁棒性与准确性。轨迹识别模块采用YOLOv8作为检测模块,基于BotSORT-ReID算法对车辆进行检测与追踪,获取其轨迹用于后续的违停行为识别。不同于原始方法中使用的特征提取模块,本研究直接利用YOLOv8所输出的特征图,并引入一种双重注意力特征融合机制以实现特征的提取与匹配。

YOLOv8在颈部网络输出三种尺度的特征图,经过解耦头处理后,这些特征在尺度、粒度及关注维度上各具差异,其所表达的特征重点亦不尽相同。为了更高效地融合这些多样化的特征输出,并增强模型在重识别任务中的特征表达能力,提出了一种融合空间注意力与通道注意力的双重注意力特征融合模块(DAFM)。图2展示了该模块的结构,其包含以下四个核心阶段:

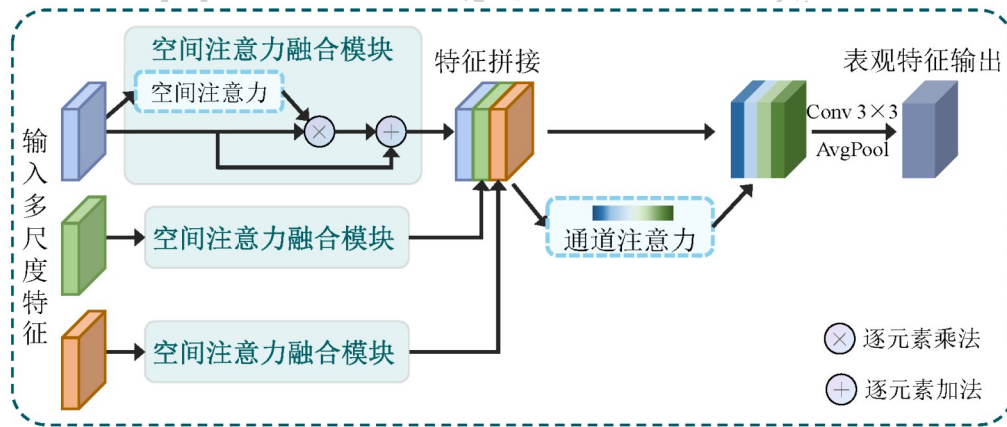


图2 双重注意力特征融合模块结构

Fig. 2 Structure of the dual attention feature fusion module

1)空间注意力融合阶段:三种不同尺度的特征分别输入空间注意力融合子模块(spatial attention fusion module, SAFM),生成增强后的特征图。利用空间注意力机制(spatial attention module, SAM)(Woo 等, 2018),动态学习特征图中各空间位置与当前任务的关联性,对关键区域赋予更高权重,使模型专注与重识别最相关的空间特征。

2)特征拼接阶段:将上述三个增强特征图在通道维度上进行拼接,通过此方式,来自不同解耦头的特征信息得以完整保留与整合,提升特征表达的多样性以及对不同视角特征的兼容性。

3)通道注意力增强阶段:由于拼接操作使得特征图的通道数增加,而各通道在任务中的作用并不一致,因此引入SEBlocks(Hu 等, 2018)实现通道注意力增强。这一机制可聚焦于对重识别具有判别力的通道,同时抑制无关或低价值信息,从而强化模型的识别能力。该结构详见图3。

4)表现特征生成阶段:为进一步挖掘融合特征中的局部判别信息,将融合注意力机制后的特征送

入一个 $3 \times 3$ 的卷积层以提取更加精细的特征细节,并通过平均池化操作进行降维,生成最终用于轨迹关联的特征向量。




图3 通道注意力SEBlocks结构图

Fig. 3 SEBlocks architecture diagram

对比当前的主流注意力机制,SENet(Hu 等, 2018)与CBAM(Woo 等, 2018)均为通用目标检测设计,未适配高速公路场景特性,DAFM的差异主要体现在以下方面:

1)注意力作用维度不同:SENet仅关注通道维度,通过全局池化与全连接层分配通道权重来筛选

有效特征;CBAM采用“先进行通道注意力处理,再开展空间注意力处理”的串行流程,筛选通道再聚焦空间区域;而DAFM则采用“先进行空间注意力增强,再开展通道注意力筛选”的组合逻辑,先对多尺度特征分别做空间增强,抑制遮挡与背景,再拼接后做通道筛选,实现双维度协同优化;

2)多尺度特征处理方式不同:SENet采用单尺度输入,没有专门多尺度处理设计,容易丢失远处小目标特征;CBAM对单尺度特征图进行注意力增强,并且其空间注意力通过 $7 \times 7$ 固定卷积核生成权重,感受野固定;DAFM则专门适配高速公路多尺度车辆场景,对YOLOv8输出的 $1/8$ 、 $1/16$ 、 $1/32$ 三种尺度特征分别进行空间注意力增强,空间注意力基于全局池化动态学习权重,可实时聚焦车辆未遮挡区域,提升抗遮挡能力;

综上所述,双重注意力特征融合模块直接利用YOLOv8的原生特征输出,无须额外图像特征提取,有效降低了系统开销并提升追踪效率。同时,通过结合空间与通道注意力机制,有效减轻了背景杂乱、遮挡及姿态变化等对特征提取造成的不利影响,增强了模型对目标区域的感知能力。

## 2.2 基于时空特征的违停判别

基于时空特征的违停判别模块的详细流程如图4所示,其中 $F(j)$ 表示车辆在第 $j$ 帧是否处于静止状态,1和0分别表示静止状态和运动状态。模块通过自适应帧间位移方法对车辆轨迹数据进行初步分析,识别出低速运动或静止的目标,即违停候选车辆。随后,针对YOLOv8识别出的夜间低光条件下的疑似目标,应用基于时序信号分析的危险报警闪光灯检测技术,进一步过滤可能的误报情况。

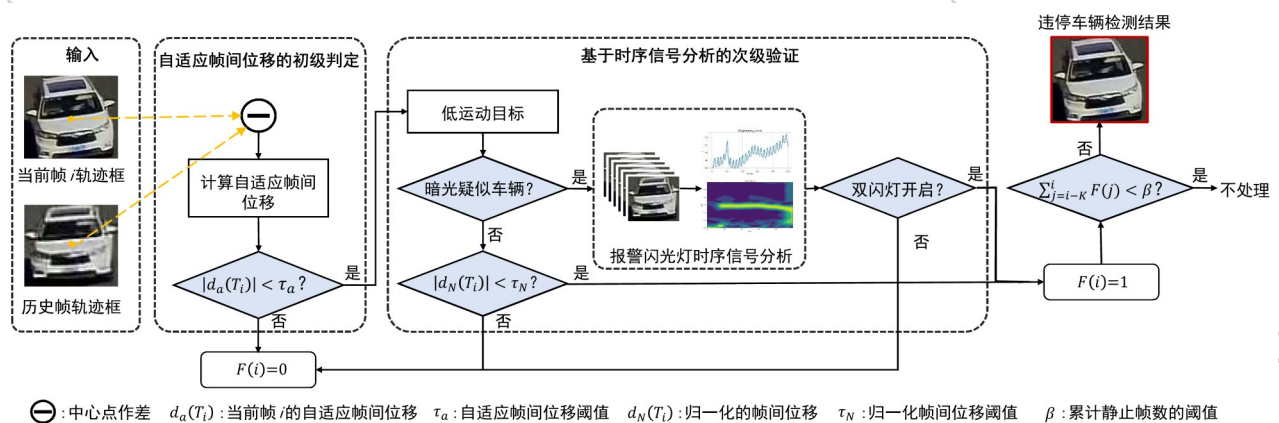


图4 基于时空特征的违停判别方法流程图

Fig. 4 Flowchart of the illegal parking detection method based on spatiotemporal features

### 2.2.1 自适应帧间位移的初级判定

在违法停车检测任务中,精准判断目标的移动状态是判定车辆是否存在违停行为的关键。然而,在实际应用中,由于目标检测框可能出现轻微抖动,以及车辆与摄像机之间距离的变化会造成透视畸变,使得直接利用相邻帧之间的位移来判断违停容易受到干扰,引入误差。为了解决这一问题,一种基于指数加权移动平均(exponentially weighted moving average, EWMA)策略的自适应帧间位移计算方法被提出。

#### 1) 归一化帧间位移

为了克服由于车辆与摄像头之间距离差异所造成的透视畸变问题,针对每一个具体的道路场景,对监控视频中车辆的运动轨迹进行了持续一段时间的

采集与分析,从而获得该场景下车辆在连续帧之间的位移数据分布情况,如图5所示。图中的纵轴反映了车辆在不同空间位置上的帧间位移幅度。根据这些数据拟合出一条标准的帧间位移参考曲线,其数学表达形式如公式(1)所示:

$$f(x) = \sum_{k=0}^K \alpha_k x^k. \quad (1)$$

式中, $x$ 表示轨迹框中心的纵向坐标, $f(x)$ 函数表示位移的拟合表达式, $k$ 为所使用的多项式拟合的阶数, $\alpha_k$ 表示对应 $k$ 次幂的系数值,这些系数可以通过最小二乘法对目标函数进行优化求解以获得。为了更有效地捕捉低速甚至静止状态下车辆的轨迹变化,引入了权重因子的加权目标函数,其形式如公式(2)所示:

$$\min \left( w_{up} \cdot \sum_{i=1}^{N_{up}} \left( y_i - \sum_{k=0}^K a_k x_i^k \right)^2 + w_{down} \cdot \sum_{j=1}^{N_{down}} \left( y_j - \sum_{k=0}^K a_k x_j^k \right)^2 \right) \quad (2)$$

式中,  $x_i, y_i$  表示所采集的轨迹中心点的纵向坐标及其对应的帧间位移值;  $w_{up}$  和  $w_{down}$  分别是分配给位于拟合曲线上方与下方的轨迹点的权重参数, 而  $N_{up}$  和  $N_{down}$  则表示这两类轨迹点的数量。如图5所示, 纵坐标代表车辆目标中心点在图像的帧间移动距离, 分布在一个区间范围内。越位于顶端即纵坐标越小, 目标的帧间位移区间越小, 运动状态越难判别。通过合理设置  $w_{up}$  和  $w_{down}$  的值, 可以使拟合曲线趋向于靠近轨迹点的下方, 有助于更精准地识别车辆的细微位移, 尤其是对于远处低速移动或接近静止的目标车辆更为敏感。




图5 车辆目标的帧间位移数据分布图

Fig. 5 Distribution diagram of inter-frame displacement data for vehicle targets

针对第  $i$  帧所对应的车辆轨迹  $T_i$ , 其中心点坐标记作  $x_i$ 。该车辆在该帧的归一化帧间位移  $d_N(T_i)$  按照公式(3)进行定义:

$$d_N(T_i) = \frac{disp(T_i)}{f(x_i)} \quad (3)$$

式中,  $disp(T_i)$  表示当前车辆目标在相邻帧之间的实际移动距离, 而  $f(x_i)$  代表该位置对应的标准参考帧间位移。通过使用归一化后的帧间位移值来判断车辆是否发生移动, 能够有效抵消由于摄像头的安装高度、拍摄角度以及镜头焦距等因素所引起的透视畸变影响, 从而使车辆移动的判定可以在统一的位

移尺度下进行, 提升计算的一致性与准确性。

## 2) 自适应帧间位移

在归一化位移的基础之上, 引入了指数加权移动平均(EWMA)的思想, 提出了自适应帧间位移的更新机制, 其计算方式如公式(4)所示:

$$d_a(T_i) = \gamma d_a(T_{i-1}) + (1 - \gamma) d_N(T_i) \quad (4)$$

式中,  $d_a(T_i)$  为当前轨迹在当前第  $i$  帧的自适应帧间位移,  $d_N(T_{i-1})$  为轨迹在上一帧的自适应帧间位移,  $d(T_i)$  为轨迹的归一化帧间位移。参数  $\gamma$  为平滑因子, 控制当前的帧间位移与上一帧的自适应帧间位移的权重, 定义为公式(5):

$$\gamma = \frac{n_{sl}(T_i)}{n_{sl}(T_{i-1}) + d(T_i) + \lambda} \quad (5)$$

式中,  $n_{sl}(T_i)$  表示从目标开始处于低速或静止状态以来, 连续处于该状态的帧数。  $\lambda$  为一个固定值, 用作轻微平滑的参数, 避免在特殊情况下分母接近零导致数值不稳定问题。通过动态调整归一化帧间位移与基于历史轨迹信息计算的自适应帧间位移之间的权重分配, 能有效应对在实际检测过程中出现的各种问题。当车辆长时间保持静止或低速状态时, 平滑因子  $\gamma$  将趋近于 1, 使得更新时更依赖历史轨迹数据, 抑制短时间内由于检测框不稳定带来的误差。一旦车辆快速启动并造成帧间位移急剧增加, 平滑因子  $\gamma$  会迅速减小, 使当前的归一化位移在更新中占据主导地位, 能快速反映车辆状态的变化, 避免将其误判为违停。

综上所述, 引入自适应帧间位移机制识别车辆的运动状态, 能根据不同的动态特性自适应调整策略, 还显著提升违停识别的鲁棒性和适应性。

### 2.2.2 基于时序信号分析的次级验证

在夜间环境中, 由于光照条件较差, 车辆的检测准确性容易受到影响, 可能出现漏检或误检的情况。为提升夜间车辆的识别能力, 引入了“暗光疑似车辆”这一新类别, 虽在一定程度上提高了车辆的检出率, 但也引发了新的问题——如路灯、反光标志灯等强光背景容易被误判为车辆。为避免此类误判进一步导致违停检测错误, 提出了一种基于时间序列信号分析的二次验证机制。

车辆的双闪警示灯是判断车辆处于特殊停放状态的重要特征, 具备显著的可识别性和典型的时间变化特征, 在特定的环境下能够有效地区分车辆和

背景。通过检测车辆危险报警闪光灯的开启状态,可以在夜间或低能见度条件下起到辅助识别的效果。鉴于危险报警闪光灯的点亮是一种动态过程,仅依赖单帧图像难以准确判断其状态。为此,提出了一种基于时间序列分析的危险报警闪光灯识别方法,通过对车辆目标区域亮度变化的周期性特征进行功率谱分析,提取关键频率成分,实现对车辆危险

报警闪光灯闪烁频率的精确识别。

如图6所示,该方法的实现过程包括两个阶段。亮度曲线的预处理阶段从历史帧的轨迹序列中提取波形信号进行预处理,曲线频谱分析阶段对预处理后的波形信号进行分析,提取主要的频率信息作为危险报警闪光灯检测的依据。

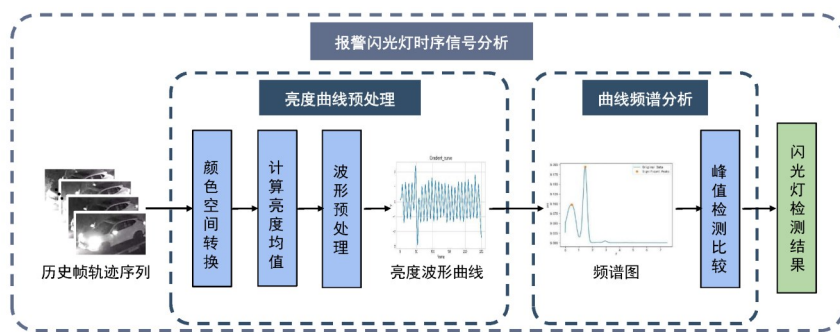


图6 危险报警闪光灯时序信号分析流程示意图

Fig. 6 Schematic diagram of hazard warning flashing light temporal signal analysis

### 1) 亮度曲线预处理

如图7所示,亮度曲线的预处理流程从连续 $n$ 帧历史帧提取目标图像序列,将提取的目标图像序列由彩色空间转换为灰度图,并计算每帧中目标区域的平均亮度值,获得一条随时间变化的表征目标在不同时间点的亮度特征亮度时序曲线。

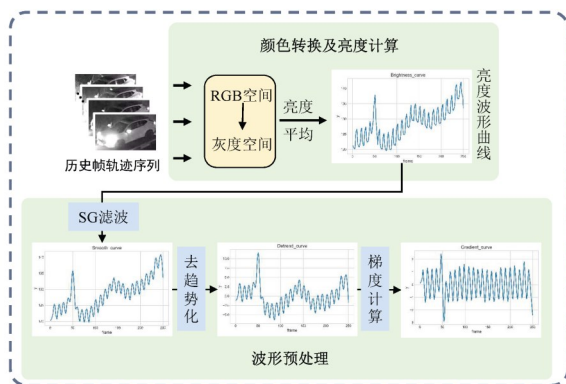


图7 亮度曲线预处理流程

Fig. 7 Brightness curve preprocessing flow

受到环境光变化、临近车辆车灯影响、目标车辆局部遮挡以及摄像头自动曝光机制等因素的影响,从前述步骤获取的亮度波形曲线中夹杂一定的噪声干扰。为减弱噪声对检测结果的影响,采用以下步骤对原始亮度曲线进行预处理:

(1) SG滤波:采用Savitzky-Golay滤波器(Wil-liam等,2007)对亮度时序信号进行平滑处理。该方法基于局部多项式拟合原理,通过一定范围内滑动窗口进行拟合运算,实现信号的平滑。滑动窗口的宽度和多项式的阶数依据波形数据的长度进行合理设定。此方法能够有效去除随机噪声同时,较好保留曲线的本征变化趋势和周期性特征。

(2)去趋势化:实际场景中,检测框内的亮度值可能存在整体缓慢变化的趋势,会掩盖危险报警闪光灯信号的特征,对后续处理造成干扰。因此通过最小二乘法拟合出一条代表整体变化趋势的直线,并将其从原始亮度信号中剔除,实现对亮度信号的去趋势化。该操作有助于消除低频背景成分的影响,使频谱分析更聚焦于真实的周期信号成分。

(3)梯度计算:为了更清晰地捕捉亮度随时间的变化特性,对时序亮度信号进行梯度运算,获取各时间点亮度的瞬时变化率。该处理方式可更直观地揭示危险报警闪光灯的闪烁节奏,使分析重点转向亮度变化速率而非其绝对值,有助于提升对周期性成分的响应敏感度。

### 2) 曲线频谱分析

图8所示为曲线频谱分析的整体流程。在完成预处理的亮度时序信号后,采用Welch方法(Welch, 1967)对该信号进行功率谱密度(power

spectral density, PSD)估计。对频谱结果执行主频峰值的检测,提取出信号中具有代表性的主导频率,据

此判断该主频是否落在车辆危险报警闪光灯的典型频率范围内。




图8 曲线频谱分析示意图

Fig. 8 Schematic diagram of curve spectrum analysis

主导峰的识别过程包括两个关键环节。第一步峰值定位,采用局部极大值搜索的方法,从功率谱密度曲线中提取出所有可能的峰点。第二步对这些候选峰值进行显著性判别与主频匹配分析。峰值的显著性通过计算其与周围谷值之间的幅度差来衡量,即衡量该峰相较于周边信号的突出程度,定量计算方法如公式(6)所示:

$$P = x[i] - \max(B_{left}, B_{right}) \quad (6)$$

式中, $x[i]$ 表示第*i*个检测到的峰值, $B_{left}$ 和 $B_{right}$ 分别对应其左右两侧的最低谷值。若某一峰值的突出度超过功率谱密度背景平均值的两倍,则可视为通过显著性评估并视为主导峰。仅当主导峰的频率落在车辆危险报警闪光灯的特定频段内,才认定该车辆开启闪光灯。该频率判定机制有效减低噪声干扰和环境光波动带来的影响,提升对闪光灯信号的识别精度。详见第3.2节的实验细节。

选取两个夜间场景视频开展暗光疑似车辆亮度曲线分析,如图9所示,视频1和视频2均识别到违停车辆,同时也存在错误的暗光疑似车辆,分别采用不同颜色框进行标注。图10为对应的识别目标的时序平均亮度图。可以看出车灯亮度闪烁时具有周期规律的特征,而背景干扰如普通路灯的亮度在时间轴上变化不大,进行亮度时序曲线频谱分析,能有效区分暗光疑似车辆与背景干扰。

### 3 实验结果与分析

#### 3.1 实验数据集

鉴于目前尚无公开面向高速公路违停检测任务的标准数据集,结合实际高速公路监控应用的需求,



图9 暗光疑似车辆图像

Fig. 9 Low-Light suspected vehicle images

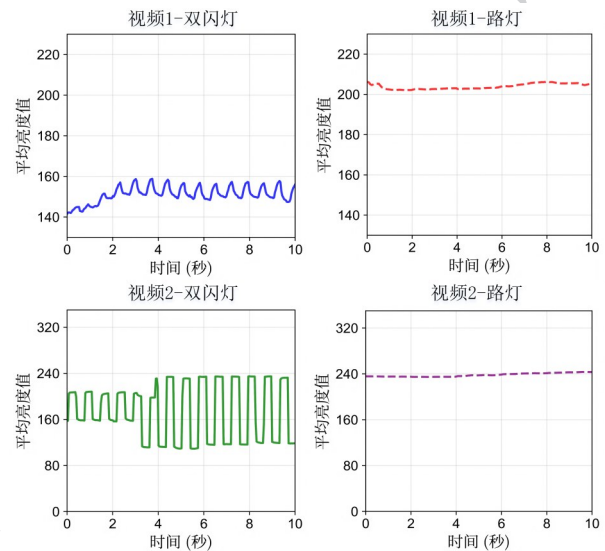


图10 疑似目标时序平均亮度图

Fig. 10 Brightness temporal graph of suspected targets

首次构建了三个针对性强、标注精细的高质量专用数据集:高速公路车辆目标检测数据集、车辆跟踪数据集和车辆违停识别视频数据集,涵盖车辆目标检测、跟踪以及违停识别等任务。数据均来源于真实高速公路监控视频片段,充分覆盖不同时间段(白天/夜间)、多种道路类型(主线/隧道)及复杂气象条件(雨雾天气),视频帧率为25帧每秒(frame per second, fps),分辨率为1920×1080或1280×720。

车辆目标检测数据集包含 8532 张图像,涵盖白天、夜间及雨天等多样化场景,按 7:3 的比例划分为训练集与测试集。夜间或低照度场景的车辆整体轮廓模糊,画面易表现为模糊光斑,单帧下难以准确识别,本文将该类目标定义为“暗光疑似车辆”并划分为一类,旨在降低夜间漏检率,并结合时序信号分析,提升夜间识别的可靠性。表 1 列出该数据集各类别目标框的数量分布,包括小型车辆、大型货车、大巴车辆以及暗光疑似车辆四类目标。图 11 展示四类目标的示例图像,用红色方框标注。

表 1 高速公路车辆检测数据集图像数据统计  
Table 1 Statistical analysis of image data in highway vehicle detection dataset

	图片数量	小型车辆	大型货车	大巴车辆	暗光疑似车辆
训练集	5990	26308	1638	1264	3610
测试集	2542	10729	663	406	1655
合计	8532	37037	2301	1670	5265



图 11 四类目标的示例图像

Fig. 11 Example images of four categories

高速公路车辆跟踪数据集由训练子集与测试子集构成,视频片段的平均时长在 30s 以上。通过以 5fps 的频率抽取图像帧,对车辆目标进行帧号标注、身份 ID 分配以及边界框位置的人工注释。表 2 列出了训练集与测试集分别包含的视频片段数量、图像帧总数以及对应的车辆轨迹数量。

高速公路车辆违停识别数据集共收录了 77 段

表 2 高速公路车辆跟踪数据集数据统计

Table 2 Statistical analysis of data in highway vehicle tracking dataset

	片段数量	图片总数	轨迹总数
训练集	25	23684	2143
测试集	11	10916	1137
合计	36	34600	3280

时长超过一分钟的视频,涵盖 98 辆发生违停行为的车辆,且每辆车的违停持续时间均超过 10s。为评估所提出算法在多种光照条件和天气环境下的适应能力,特别是在夜间环境中仍具备良好检测性能和较低误报率,数据集特意选取了来自不同路段与时段的视频资料。该数据集具体划分为夜间、白天和隧道三类典型场景。各场景中视频片段数量及对应的违停车辆统计信息详见表 3。为进一步检验算法在复杂天气条件下的鲁棒性,每类场景中还包含了如雨天、浓雾等恶劣气象条件下的样本片段。图 12 展示部分典型场景的示例图像。

表 3 车辆违停识别数据集不同场景片段数量统计  
Table 3 Statistical analysis of the number of scene segments in the vehicle illegal parking detection dataset

场景	夜间	白天	隧道	合计
片段数量	27	27	23	77
违停车辆数	39	34	25	98




图 12 车辆违停识别数据集不同场景图片展示

Fig. 12 Display of images from different scenarios in the vehicle illegal parking detection dataset

### 3.2 实验配置

1) 硬件配置: 系统为 Ubuntu20.04; CPU 配置 2 个英特尔 Xeon Silver 4210; 内存共为 32GB; 并配置一张 RTX 5000 GPU, 显存为 16GB GDDR6。

2)评估指标:为了全面评估高速公路车辆违停识别算法的性能,采用了准确率(Precision, P)、召回率(Recall, R)、F1分数、使用显存以及fps指标,对车辆违停判别模块的有效性进行量化分析。若系统在车辆违停期间成功识别该目标,则视为一次正确检测(True Positive, TP),否则记为漏检(False Negative, FN)。此外,为验证所引入的双重注意力特征融合机制对车辆跟踪结果的增强效果,进一步采用多目标跟踪准确率(multiple object tracking accuracy, MOTA)、身份F1分数(ID F1 Score, IDF1)以及高阶跟踪精度(higher order tracking accuracy, HOTA)(Luiten等,2021)三项主流指标,对车辆跟踪子模块的性能进行系统性评估。对跟踪算法性能增加fps指标,衡量跟踪算法速度。

3)实验细节:根据实际场景的应用需求,车辆判定为违停的最小静止时间设定为 $D=10s$ 。考虑到车辆从运动状态过渡到完全静止的过程,累计静止帧的阈值 $\beta$ 设定为 $0.8*D$ 。在帧间自适应位移判定模块中,参数设定为 $w_{up}=0.25, w_{down}=0.75, \tau_a=\tau_N=1$ 。平滑因子 $\gamma$ 是由公式(5)定义给出,其中平滑参数 $\lambda=0.01$ ,避免分母接近零而导致的数值不稳定问题。对于多项式阶数 $k$ 本文进行了不同 $k$ 值的车辆检测算法效果的比较,如表4。

表4 不同多项式阶数下车辆违停识别结果

Table 4 Results of vehicle illegal parking detection under different polynomial orders

$k$ 值	准确率	召回率	F1分数
$k=1$	68.14%	78.57%	0.73
$k=2$	88.89%	89.80%	0.89
$k=3$	<b>94.79%</b>	<b>92.86%</b>	<b>0.94</b>
$k=4$	90.91%	91.84%	0.91
$k=5$	88.54%	86.73%	0.88

注:加粗字体为每列最优值。

从表4中可以看出当 $k=3$ 时,检测算法效果最好,后续研究选择 $k=3$ 。在基于时序亮度信号进行验证阶段,借助Python中scipy.signal库实现各关键处理步骤。Savitzky-Golay滤波使用savgol\_filter函数完成,其中sample\_rate为视频帧率,窗口长度window\_length设定为sample\_rate//4;趋势项去除使用detrend函数实现;welch功率方法使用

welch函数实现,窗口大小window设定为时序信号长度的1/4;局部峰值的提取通过find\_peaks函数完成,其返回的显著性数值用于判断峰值的重要程度。依据国家标准,汽车电子闪光器的正常工作频率为每分钟60~120次,折算为1到2Hz。将车辆危险报警闪光灯的主频判定区间设定为 $[0.5, 2]$ Hz,确保检测系统对合法频率范围内的闪烁模式具备良好的识别能力。

### 3.3 实验结果

#### 3.2.1 违停识别实验结果

表5展示了所提出的车辆违停识别算法在自建的高速公路违停识别数据集上的实验结果。在夜间危险报警闪光灯违停的测试场景中,共有25段视频在目标成功被检测的前提下均实现了准确识别,另外2段因目标车辆未能被检测出,导致系统无法完成违停判断。部分典型的检测成功与失败案例如图13所示。其中第一行是为检测成功的例子,第一列显示车辆停在应急车道,旁边车道持续有车辆经过;第二列显示夜间车辆停在应急车道并有双闪,没有车辆轮廓信息;第三列显示车辆多次在应急车道缓行和停止,均被检测到。第二行是检测失败的例子。第一列图像显示道路远端的两车相撞,其中一辆无法识别;第二列显示多辆违停车辆存在遮挡状态,部分违停车辆无法识别;第三列显示隧道远端持续缓行的货车,自适应帧间位移无法判别其处于运动的状态导致误报。其中,漏检的主要原因包括车辆因遮挡或处于画面远端尺寸过小,导致目标监测失败;而误检情况则多由车辆缓慢移动而非真正静止引起,系统未能将其判断为违停。这些失败的样例在后续对比实验中所采用的三种方法中同样未能正确识别,体现出此类边界场景的挑战性。

表5 违停识别算法实验结果

Table 4 Experimental results of the proposed algorithm for illegal parking detection

准确率	召回率	F1分数	显存	fps
94.79%	92.86%	0.94	2.6 GB	32

该实验结果表明本文提出的算法在召回率与准确率之间实现较理想的权衡,不仅在保持较高检出能力的同时,有效降低了误判的发生概率,展现出良好的整体检测性能。



图 13 车辆部分违停识别例子

Fig. 13 Examples of partial vehicle illegal parking detection

### 3.2.2 车辆跟踪实验结果

为评估所提出的基于双重注意力特征融合机制的目标跟踪方法的实际效果,选取了现有多目标跟踪领域中六种具有代表性的算法作为对比基准,分别为 BotSORT (Aharon 等, 2022)、Bytetrack (Zhang 等, 2022)、StrongSORT (Du 等, 2023)、Deep OC-SORT (Maggiolino 等, 2023)、MambaTrack (Xiao 等, 2024) 和 BoostTrack++ (Stanojević 等, 2024)。

在实验过程中,首先在构建的高速公路车辆检测数据集上对目标检测模型进行训练;用于提取外观特征的子网络同样在高速公路车辆多目标跟踪训练集上完成训练。最终,将各方法高速公路车辆多目标跟踪测试集上进行实验对比,其性能指标结果如表 6 所示。

表 6 高速公路车辆跟踪实验结果

Table 5 Experimental results of highway vehicle tracking

方法	HOTA	MOTA	IDF1	fps
Bytetrack	62.9%	75.4%	70.8%	126
BotSORT	64.1%	75.8%	68.7%	46
StrongSORT	65.4%	77.1%	73.6%	5
Deep OC-SORT	62.4%	73.3%	66.4%	6
MambaTrack	66.7%	78.8%	77.8%	16
BoostTrack++	<b>67.2%</b>	<b>79.2%</b>	<b>78.4%</b>	24
双重注意力	66.3%	77.4%	75.3%	52

注:加粗字体为每列最优值。

从实验结果可以看出,提出的算法在主要评估指标上均展现出较强的性能。在 HOTA 指标上,方法达到了 66.3% 的得分,检测效果和运算速度对比 BotSORT 具有明显的提升,BoostTrack++ 虽然在 HOTA、MOTA 和 IDF1 上表现最优,但是其运算速度明显比提出的算法慢,进一步验证了本方法在同时

考虑检测精度与数据关联准确性方面具备更强的综合优势。这一结果表明,提出的算法在单帧检测表现优秀,增强在目标跟踪过程中保持身份相对稳定的能力,降低身份切换频率与轨迹碎片的数量,提升整个跟踪流程的连贯性。

### 3.4 对比实验

为验证所提出的高速公路车辆违停识别方法的有效性,本节将其与四种现有的违停识别技术进行对比实验,比较整体算法流程的性能表现。具体而言,方法一(梁睿琳 等, 2022)采用 YOLOv4 对车辆进行检测,借助透视关系建模将远处与近处的车辆目标统一到相同的尺度体系,构建时空信息矩阵进行违停识别。方法二(Hamzah 等, 2022)依托 Inception V2 (Ioffe 等, 2016) 与 Faster R-CNN (Ren 等, 2017) 框架,将车辆违停识别问题转化为一个图像分类任务。方法三(Chen 等, 2025)引入膨胀空间金字塔池化(dilated spatial pyramid pooling, DSPP)和带分支注意力机制的膨胀空间金字塔池化(dilated spatial pyramid pooling with branch attention, DSPPA)模块改进 YOLOv8 网络的特征金字塔池化层,并设计基于全局匹配的停车位分配策略进行违规停车的监测。方法四(Kuo 等, 2024)以 YOLOP 作为网络架构框架,通过整合 YOLOv7 中的 E-ELAN 模块和 Rep-ConvN 等模块,优化模型架构,降低参数和浮点运算。各项对比实验的评估结果如表 7 所示。可以看出,提出的检测方法在准确率、召回率以及 F1 分数这三项核心评价指标上均取得了最优表现,整体优于所选的四种对比方案。其中,方法一基于透视模型配合 YOLOv4 的策略,存在较严重的漏检现象,误报率偏高。使用 Faster R-CNN 结合 Inception V2 的方法二略有提升,但整体精度仍然不高。方法三采用 YOLOv8 结合全局匹配策略的算法,召回率和处理速度比方法二效果好,但准确率略低;方法四的检测效果在四个比较算法中的检测效果最好,但夜间场景下不佳,存在较严重的漏检误检。

相比之下,本文提出的方法在检测完整性与准确性之间实现更理想的平衡,精度提升至 94.79%,召回率达到 92.86%, F1 分数为 0.94,表明本方法在有效降低漏检数量的同时,并未引入额外的误报,并且算法速度上仅次于方法三,验证了算法在实际应用中的可靠性与优越性。

同时,表 7 可以看出,本文算法在子场景性能一  
© 中国图象图形学报版权所有

致性上表现突出,夜间、白天、隧道子场景的F1 分别达 0.91、0.95、0.92,最大值与最小值差值仅 0.04,远优于方法一(0.19)、方法二(0.14)、方法三(0.15)和方法四(0.16),稳定性源于次级验证模块的作用。该模块通过分析亮度时序信号的周期性与稳定性,

有效降低夜间路灯反光、隧道照明光斑等场景干扰,降低夜间、隧道子场景的误判率,说明算法在数据分布差异较大的环境中保持稳定性能,体现算法的跨场景适应性。

表7 车辆违停识别对比实验结果

Table 7 Comparative experimental results of vehicle illegal parking detection

方法	夜间				白天				隧道				平均				
	P(%)	R(%)	F1	fps	P(%)	R(%)	F1	fps	P(%)	R(%)	F1	fps	P(%)	R(%)	F1	显存	fps
方法一	65.63	53.85	0.59	29	76.47	78.79	0.78	28	70.37	73.08	0.72	28	70.97	70.41	0.71	2.1 GB	28
方法二	65.79	64.10	0.65	31	84.38	81.82	0.83	30	83.33	76.92	0.80	30	76.60	77.55	0.77	2.3 GB	30
方法三	69.23	69.23	0.69	40	80.56	87.88	0.84	37	80.77	80.77	0.81	38	76.24	81.63	0.79	2.5 GB	38
方法四	74.36	74.36	0.74	26	88.24	90.91	0.90	26	84.62	84.62	0.85	27	81.82	86.42	0.84	1.8 GB	27
本文	<b>92.11</b>	<b>89.74</b>	<b>0.91</b>	28	<b>93.94</b>	<b>96.97</b>	<b>0.95</b>	34	<b>92.00</b>	<b>92.31</b>	<b>0.92</b>	31	<b>94.79</b>	<b>92.86</b>	<b>0.94</b>	2.6 GB	32

注:加粗字体为每列最优值。

### 3.5 消融实验

#### 3.5.1 DAFM子模块消融实验

为验证双重注意力特征融合模块中空间注意力子模块、通道注意力子模块的独立贡献及两者组合的协同效应,本研究设计了该模块的消融实验,分析各模块对高速公路车辆跟踪性能的影响。

研究选用YOLOv8作为主干检测网络,搭配BotSORT-ReID实现车辆跟踪与身份关联,作为无注意力机制的基线模型;组别2(仅SAM)中仅在YOLOv8的多尺度特征层(1/8、1/16、1/32)嵌入空间注意力子模块(SAM),不引入通道注意力;组别3(仅SEBlocks)则在YOLOv8-s的特征融合层嵌入通道注意力子模块,不引入空间注意力;组别4(DAFM)为本文完整的设计。实验结果如表8。可以看出,以基线(组别1)为参照,单独加入SAM(组别2)时,MOTA提升1.1%、IDF1提升4.5%,这是由于SAM子模块抑制背景与车辆遮挡,提升定位准确性;单独加入SEBlocks(组别3),由于可筛选车辆关键特征通道,减少远端小目标漏检,指标有一定的提升。SAM与SEBlocks组合的完整DAFM(组别4)所有指标最优,证明二者形成互补优化,有效应对高速公路多尺度车辆、密集遮挡等场景痛点。

#### 3.5.2 违停判别模块消融实验

为全面评估各功能模块在提升高速公路车辆违停识别准确性方面的实际价值,开展一系列消融实

表8 DAFM子模块消融实验

Table 8 Ablation Experiment on DAFM Sub-modules

实验组别	HOTA	MOTA	IDF1
1(Baseline)	64.1%	75.8%	68.7%
2(仅SAM)	65.8%	76.9%	73.2%
3(仅SEBlocks)	64.7%	76.1%	71.4%
4(DAFM)	<b>66.3%</b>	<b>77.4%</b>	<b>75.3%</b>

注:加粗字体为每列最优值。

验,围绕提出的三项关键创新模块展开验证,包括:基于双重注意力特征融合的表现特征提取模块、自适应的帧间位移判定机制,以及利用时序信号分析进行的次级判别模块。实验中所采用的基线方案以YOLOv8作为车辆检测器,借助BotSORT进行多目标跟踪,当相邻两帧的IoU大于0.3时,判断车辆未发生位移,若该状态持续超过10秒,则认定为违停。在此基础上,依次引入上述三个功能模块。方案一在基线方法的基础上进行了两项改进:在目标检测类别中新增“暗光疑似车辆”类别,适应低照度场景下的检测需求;同时引入双重注意力特征融合的表现特征提取模块,验证增强目标在轨迹关联过程中的特征表达能力。方案二在方案一的基础上,将IoU阈值的判定标准替换为自适应帧间位移策略,评估该机制在应对检测框轻微抖动和提升判定稳定性方面的效果。方案三进一步集成基于时序信号分

析的危险报警闪光灯检测模块,形成完整的检测流程。

表9 高速车辆违停识别消融实验结果

Table 9 Ablation experimental results of highway vehicle illegal parking detection


方法	DAFM	AID	TSA	P(%)	R(%)	F1
基线算法	-	-	-	71.16	75.51	0.73
方案一	√	-	-	63.23	80.61	0.71
方案二	√	√	-	80.90	90.82	0.86
本文方法	√	√	√	<b>94.79</b>	<b>92.86</b>	<b>0.94</b>

注:加粗字体为每列最优值。

表9展示各项实验方案的具体结果。基线方法在违停识别任务中的表现一般,召回率仅为75.51%。方案一在保留基线架构的基础上引入表观特征提取模块,召回率提升了5.1个百分点,主要得益于跟踪阶段车辆身份保持能力的增强,使得基线中因ID混淆导致的漏检目标能够被重新捕捉。但由于增加新类别,使得部分类似反光标识的非车辆目标被误判,拉低准确率。方案二在此基础上引入自适应帧间位移判断机制,使违停识别对框体抖动等干扰更加鲁棒。具体表现为准确率提高至80.9%,F1值提升至0.86,漏检现象显著减少。方案三集成危险报警闪光灯检测模块,有效解决夜间场景下误检频发的问题,三个指标均为最优,F1分数达到0.94。数据说明暗光疑似类别与双闪检测模块形成良好的协同效应,有效提升夜间场景的检测效果,验证了所提出方法的可靠性与优越性。

图14展示了车辆之间发生遮挡时的典型情形。图14(a)所示为视频第190帧画面,应急车道上违停的轿车和正常通行的车辆均被检测并被赋予身份编号。图14(b)对应第200帧,一辆行驶中的货车遮挡了违停车辆。此时基线方法的跟踪框出现误关联,主要原因是夜间光线较差,车辆的外观特征不够显著。方案一引入表观特征提取模块有效缓解该问题,避免ID匹配错误引发的漏检。

图15的白天场景显示画面远端存在正在行驶的货车,基线算法和方案一使用IoU判定策略,导致产生误检。方案二引入自适应帧间位移判别方法,能够有效地适应距离产生的透视畸变,成功识别该货车为低速移动状态,并以蓝色框进行标注。



((a) tracking result at frame 190; (b) tracking result at frame 200)

图14 表观特征提取模块有效性的实验结果示例图

Fig. 14 Example diagram of experimental results for the effectiveness of the appearance feature extraction module

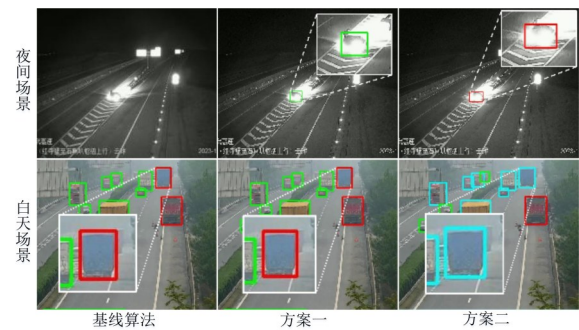


图15 自适应帧间位移的实验结果示例图

Fig. 15 Example diagram of experimental results for adaptive inter-frame displacement

图16展示引入的基于时序信号频谱分析的二次验证模块的实际效果。图16(a)和16(b)分别显示强烈反光的路牌和夜间远处路口区域持续出现光斑,均误识别为暗光疑似车辆类别,而方案一和方案二均错误判别违停。方案三经过时序信号频谱分析的验证后准确排除该误检。

## 4 结语

针对高速公路违停检测的身份混淆、透视变形及夜间场景鲁棒性问题,提出了融合双重注意力特征和时空特征的违停识别算法。首先设计了双重注意力特征融合模块以强化关键特征表达,然后通过自适应帧间位移算法处理透视变形和框抖动问题,并提出基于时序信号分析的闪光灯检测算法,提升

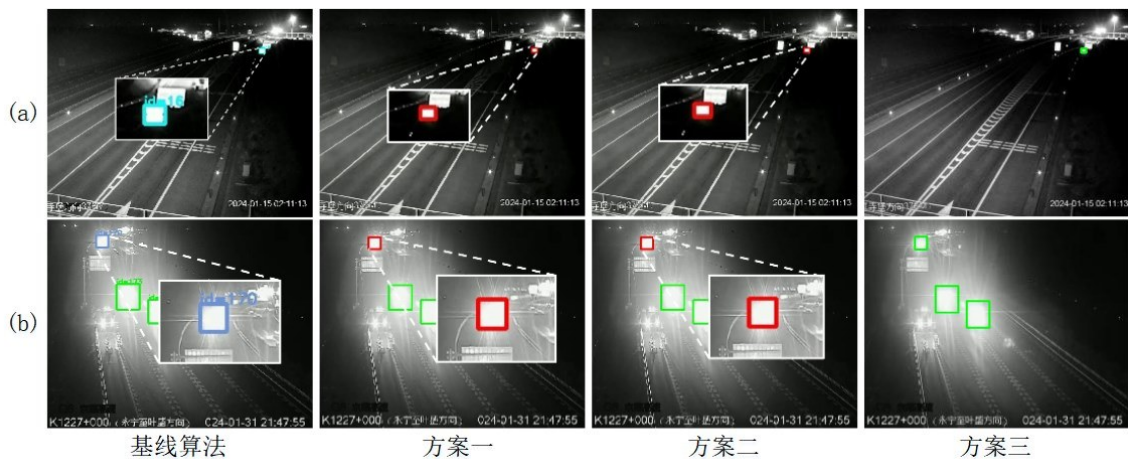


图 16 基于时序信号分析的次级验证的实验结果示例图

Fig. 16 Example diagram of experimental results for secondary verification based on temporal signal analysis

夜间判定效果。针对公开数据资源的不足,并构建了具有代表性涵盖多场景的数据集,为算法评估提供可靠支撑,提升了研究的可复现性与实用性。通过该高速公路违停数据集,评估了所提出的算法性能。实验结果表明,该算法在不同时间段和天气条件下具有良好的鲁棒性,准确率和召回率表现优异。未来将扩展数据集规模,增加跨区域与跨时段样本,提升算法的泛化能力和适应性。

### 参考文献 (References)

- Aharon N, Orfaig R and Bobrovsky B Z. 2022. BoT-SORT: Robust Associations Multi-Pedestrian Tracking[EB/OL]. [2025-04-10]. <http://arxiv.org/pdf/2206.14651v1>.
- Chen Y, Luo S, Deng X and Wu J. 2025. Lightweight Attention Modules for Real-Time Object Detection in Resource-Constrained Traffic Monitoring Systems. *Expert Systems with Applications*, 245: 123087 [DOI: 10.1016/j.eswa.2025.123087].
- Du Y, Zhao Z, Song Y, Zhao Y, Su F, Gong T and Meng H. 2023. StrongSORT: Make DeepSORT Great Again. *IEEE Transactions on Multimedia*, 8725-8737 [DOI: 10.1109/TMM.2023.3240881].
- Hamzah R A, Setianingsih C, Nugrahaeni R A, Hanafia S R and Fuadi F. 2022. Parking violation detection on the roadside of toll roads with intelligent transportation system using Faster R-CNN algorithm//Proceedings of 2022 6th International Conference on Informatics and Computational Sciences (ICICoS). IEEE: 169-174 [DOI: 10.1109/ICICoS56336.2022.9930590].
- Hassan W, Birch P, Young R and Chatwin C. 2012. Real-time occlusion tolerant detection of illegally parked vehicles. *International Journal of Control Automation & Systems*, 10: 972-981 [DOI: 10.1007/s12555-012-0514-2].
- Hu J, Shen L and Sun G. 2018. Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42 (8): 2011-2023 [DOI: 10.1109/TPAMI.2019.2913372].
- Ioffe S and Szegedy C. 2016. Batch normalization: Accelerating deep network training by reducing internal covariate shift//Proceedings of the 32nd International Conference on Machine Learning (ICML). PMLR: 448-456 [DOI: 10.48550/arXiv.1502.03167].
- Ketcham M, Ganokratana T, Gedkhaw E, Piyaneerant M and Yimyan W. 2019. Recognizing illegal parking patterns of cars on the road in front of a bus stop using support vector machine//Proceedings of 2019 15th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS). IEEE: 538-542 [DOI: 10.1109/SITIS.2019.00091].
- Kuo L C and Lin H Y. 2024. Illegal parking detection based on multi-task driving perception//Proceedings of 2024 IEEE Intelligent Vehicles Symposium (IV). IEEE: 1865-1870 [DOI: 10.1109/iv55156.2024.10588798].
- Liang R L, Wang R and Guo Y. 2022. Abnormal Parking Detection on Highways Based on Video Spatiotemporal Relationships. *Computer Application Research*, 39(06): 1916-1920 (梁睿琳,王锐,郭迎. 2022. 基于视频时空关系的高速公路异常停车检测. *计算机应用研究*, 39(06): 1916-1920 [DOI: 10.19734/j.issn.1001-3695.2021.09.0617].
- Luiten J, Osep A, Dendorfer P, Torr P, Geiger A, Leal-Taixe L and Leibe B. 2021. HOTA: A Higher Order Metric for Evaluating Multi-object Tracking. *International Journal of Computer Vision*, 129: 548-578 [DOI: 10.1007/s11263-020-01375-2].
- Maggiolino G, Ahmad A, Cao J and Kitani K. 2023. Deep OC-SORT: Multi-pedestrian tracking by adaptive re-identification//Proceedings of 2023 IEEE International Conference on Image Processing (ICIP). Kuala Lumpur, Malaysia: IEEE: 3025-3029 [DOI: 10.1109/ICIP49359.2023.10222576].
- Matsuda A, Matsui T, Matsuda Y, Suwa H and Yasumoto K. 2021. A

- system for real-time on-street parking detection and visualization on an edge device//Proceedings of 2021 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops). IEEE: 227-232 [DOI: 10.1109/PerCom-Workshops51409.2021.9431076].
- Park H, Kim K, Jeong I, Jung J, Cho J and Access I. 2025. Special Vehicle Classification Algorithm-Based System for Dedicated Parking Zone Violation Detection in South Korea. IEEE Access, 13: 7883-7901 [DOI: 10.1109/ACCESS.2025.3526862].
- Peng X, Song R, Cao Q, Li Y, Cui D, Jia X, Lin Z and Huang G B. 2022. Real-Time Illegal Parking Detection Algorithm in Urban Environments. IEEE Transactions on Intelligent Transportation Systems, 23 (11): 20572-20587 [DOI: 10.1109/TITS. 2022. 3180225].
- 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 (6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031].
- Stanojević V and Todorović B. 2024. BoostTrack++: using tracklet information to detect more objects in multiple object tracking [EB/OL]. [2025-03-23]. <http://arxiv.org/pdf/2408.13003v1>
- Yu Y, Chen W X and Chen F X. 2023. RIC-NVNet: night-time vehicle enhancement network for vehicle model recognition. Journal of Image and Graphics, 28 (07): 2054-2067 (余焯, 陈维笑, 陈凤欣. 2023. 面向车型识别的夜间车辆图像增强网络 RIC-NVNet. 中国图象图形学报, 28 (07): 2054-2067) [DOI: 10.11834/jig. 220122].
- Wahyono, Filonenko A and Jo K H. 2016. Detecting illegally parked vehicle based on cumulative dual foreground difference//Proceedings of 2016 IEEE 14th International Conference on Industrial Informatics (INDIN). France: IEEE: 772-775 [DOI: 10.1109/INDIN.2016.7819263].
- Wang Q, Xue X Y, Min W D, et al. 2024. Cross-domain joint learning and shared subspace metric for vehicle re-identification. Journal of Image and Graphics, 29 (05): 1364-1380 (汪琦, 雪心远, 闵卫东. 2024. 跨域联合学习与共享子空间度量的车辆重识别. 中国图象图形学报, 29 (05): 1364-1380) [DOI: 10.11834/jig. 230405].
- Welch P D. 1967. The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. IEEE Transactions on Audio and Electroacoustics, 15(2): 70-73 [DOI: 10.1109/TAU.1967.1161901].
- William H P, Brian P F, Saul A T and William T V. 2007. Numerical Recipes: The Art of Scientific Computing. Cambridge: Cambridge University Press [DOI: 10.1007/BF01321860].
- Woo S, Park J, Lee J Y and Kweon I S. 2018. CBAM: Convolutional block attention module//Proceedings of the European Conference on Computer Vision (ECCV). 3-19 [DOI: 10.1007/978-3-030-01234-2\_1].
- Xiao C C, Cao Q, Luo Z G and Lan L. 2024. MambaTrack: A simple baseline for multiple object tracking with state space model//Proceedings of the 32nd ACM International Conference on Multimedia. 4082-4091 [DOI: 10.1145/3664647.3680944].
- Xie X, Wang C, Chen S, Shi G and Zhao Z. 2017. Real-time illegal parking detection system based on deep learning//Proceedings of the 2017 International Conference on Deep Learning Technologies (ICDLT). 23-27 [DOI: 10.1145/3094243.3094261].
- Xu H, Dong S H, Zhang J W, et al. 2025. Context-aware attention fused Transformer tracking. Journal of Image and Graphics, 30 (01): 212-224 (徐哈, 董仕豪, 张家伟. 2025. 融合上下文感知注意力的Transformer目标跟踪方法. 中国图象图形学报, 30(01): 212-224) [DOI: 10.11834/jig.240084].
- Zhang Q, Li M, Huang T and Zhou B. 2024. Cross-frame interaction attention for vehicle trajectory and behavior modeling in traffic surveillance//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE: 13521-13530 [DOI: 10.1109/CVPR52733.2024.01352].
- Zhang Y, Sun P, Jiang Y, Yu D, Weng F, Yuan Z and Wang X. 2022. ByteTrack: Multi-object tracking by associating every detection box//Proceedings of the European Conference on Computer Vision (ECCV). Springer Nature: 1-21 [DOI: 10.1007/978-3-031-20047-2\_1].

## 作者简介

尹娜,女,硕士研究生,主要研究方向为计算机视觉和目标检测。E-mail:202220143482@mail.scut.edu.cn

张泽宁,男,软件工程师,主要研究方向为计算机视觉、自然语言处理、生成式模型以及多模态学习。E-mail: zznmiz-zou@gmail.com

吕洪燕,男,正高级工程师,主要研究方向为智能交通、交通管控和深度学习。E-mail: lhy@runonotech.com

罗旭彬,男,软件工程师,主要研究方向为计算机视觉、自然语言处理和模式识别。E-mail: 515664321@qq.com