

基于视频检测的交通流量识别准确性分析

余泽明

云南省交通科学研究院有限公司交通信息技术分公司 云南 昆明 650000

【摘要】：本文针对视频交通流量检测技术开展系统研究，梳理传统视频车辆检测、基于深度学习的车辆检测、交通流量提取及模型优化等技术基础，设计单级特征检测网络架构，融入目标跟踪模块，从损失函数、训练策略与数据集构建等方面完成模型优化。分析环境、车辆特征、模型参数及硬件资源对识别准确性的作用，借助多场景对比实验完成模型性能验证。优化后的融合模型在遮挡、光照变化、复杂交通状态下具备更强适应能力，计数精度与实时性保持良好平衡，相比传统方法具备明显优势，可为智能交通流量监测提供可靠技术支撑。

【关键词】：视频交通流量检测；深度学习；目标检测；目标跟踪；车辆计数

DOI:10.12417/2811-0722.26.04.040

引言

智能交通系统快速发展，视频交通流量检测凭借非接触、易部署、信息丰富成为研究热点。传统检测方法依赖人工设计特征，复杂场景中精度受限，深度学习技术为车辆检测与流量统计提供新路径。车辆检测仍面临遮挡、尺度变化、光照干扰等问题，流量统计常出现漏计、重复计数现象。基于现有技术基础，设计轻量化单级特征检测网络，融合优化跟踪模块，系统分析准确性影响因素，通过实验验证模型有效性，提升复杂交通场景下流量识别的精度与稳定性，推动视频检测技术在实际交通管控中的应用。

1 视频交通流量检测相关技术基础

1.1 传统视频车辆检测技术

传统视频车辆检测技术遵循“候选区域生成-验证”两阶段流程。候选区域生成核心是挖掘车辆颜色、对称性、角点等固有特征锁定目标，研究者用特定编码表征像素变化，或利用亮度、色度、车辆阴影等特征筛选区域^[1]。验证阶段采用模板匹配和外观特征学习两种方法，模板匹配针对车辆视图设计专用模板，部分模型分区域匹配改善遮挡漏检问题；外观特征学习从训练图像提取特征并建模，部分研究融合多种特征优化性能。这类方法依托特定图像操作实现，响应速度较快，检测精度却受场景影响显著，复杂环境下会随视频质量下降大幅降低。

1.2 基于深度学习的视频车辆检测技术

基于深度学习的视频车辆检测技术主要分为三类。二阶段目标检测以“候选区域生成-分类回归”为核心，早期模型存在预选框冗余、训练时间长等问题，后续改进模型实现端到端优化，或采用专用网络、空间金字塔结构提升性能。一阶段目标检测跳过候选区域生成，单卷积神经网络直接映射边界框与类别，典型模型经迭代融合多种结构优化性能，部分借助多尺度卷积核、创新损失函数解决相关问题。基于 Transformer 的模型借鉴自然语言处理编解码结构，将检测视为集合预测问

题，自我注意力机制并行输出结果，无需预选框、锚点及相关后处理操作。

1.3 交通流量提取核心方法分类

交通流量提取核心方法分为三类。基于检测的目标计数方法，先检测视频帧车辆再统计个数，研究者用特定模型匹配不同帧车辆实现计数，易受遮挡影响，检测精度直接决定统计准确性^[2]。基于回归的方法提取局部或全局特征，建立与车辆数目的映射关系，无需检测单个目标，响应速度快，却会损失空间和语义信息，低分辨率下精度较差，部分研究借助多样特征融合优化效果。基于密度估计的方法，将计数转化为密度估计任务，映射像素或特征为密度图，求和得到车辆数目，可保留空间信息，计算复杂度却较高，目标尺寸变化会影响准确率。

1.4 深度学习模型优化技术

深度学习模型优化技术核心是高效算法最小化损失函数，提升训练效率与性能，主要分为梯度下降和自适应学习率两类算法。梯度下降算法中，基础方法选取部分样本计算梯度更新参数，学习率设置至关重要；改进方法可减少参数波动、加速收敛，也能提高训练效率。自适应学习率算法可自动调节学习率，无需手动干预，部分适合稀疏数据却存在学习率骤降问题，另有通过超参数控制学习率变化，还有结合动量项与自适应优势，内存需求小、收敛快，适配大数据集。算法选择需结合网络结构与数据集特点，实现最佳训练效果。

2 视频交通流量检测模型设计与构建

2.1 单级特征检测网络架构设计

单级特征检测网络架构设计核心是简化网络并保证精度，以特定网络为基础构建架构，由主干网络、编码器、解码器组成。主干网络选用特定类型网络，经公开数据集预训练获取特征提取能力，输出特定特征图，可缓解梯度冗余，兼顾速度与准确率。编码器用单输入单输出结构替代复杂特征金字塔网络，通过扩张编码器和均匀匹配实现跨尺度融合，扩张编码器由投影层和残差块构成，合理设置扩张率覆盖不同尺寸车辆；

均匀匹配解决锚点稀疏问题，分配正向锚点并设置阈值。解码器参考经典结构，包含分类头和回归头，回归头添加隐式对象预测分支，优化类别判断与目标置信度。

2.2 目标跟踪模块融合策略

目标跟踪模块融合核心是解决车辆遮挡、ID 切换问题，采用特定融合架构，结合单级特征检测网络与改进跟踪算法^[3]。跟踪流程遵循“检测-关联-更新”逻辑，通过检测网络输出车辆检测框、置信度等信息，再输入跟踪模块进行帧间关联。关联采用级联匹配与 IoU 匹配结合，级联匹配优先匹配短消失轨迹，融合运动与表面特征构建代价矩阵；IoU 匹配补充关联未确认或短保留时长轨迹，缓解遮挡问题。相关滤波采用特定模型，动态估计目标状态，设定最大保存时间删除无效轨迹。引入数据增强和自对抗训练，提升小目标跟踪能力与样本抗干扰性，保障复杂场景下的稳定性。

2.3 损失函数与训练方法优化

损失函数设计采用分类损失与回归损失融合，兼顾类别判断与边界框定位精度。分类损失选用特定损失函数，两个超参数平衡正负样本权重、压制简单样本损失，改进经典损失函数缓解训练偏差。回归损失选用特定损失函数，相比传统方法，兼顾重叠区域与最小闭包区域，无重叠时仍可实现梯度更新，提升定位准确性。总损失为两类损失求和，简化超参数调节。训练采用特定梯度下降算法，多 GPU 并行训练，合理设置批量大小、学习率及预热迭代次数，特定节点调整学习率。引入多种数据增强策略，重点优化车辆遮挡、尺度变化的适应性训练，增强模型泛化能力（见图 1）。

损失函数设计与训练策略

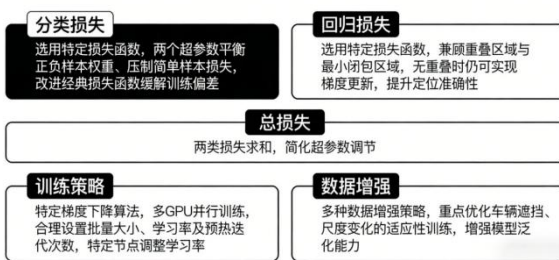


图 1 损失函数设计预训练策划

2.4 数据集构建与预处理

数据集构建以真实交通场景为核心，保证代表性与多样性，采集于城市不同典型路口，覆盖早晚高峰，跨度一定周期，涵盖多种光照和天气条件。数据集包含一定数量视频片段，按交通状态分为五类，样本数量均衡，对样本较少类别进行数据扩充。每个视频片段标注车辆检测框、类别、轨迹 ID 及交通状态，严格区分行驶与停放车辆。预处理包含三步：视频帧提取，用专业工具按特定频率提取并调整尺寸；数据增强，除训

练阶段方法外，还进行翻转、亮度调整等处理；格式转换，将标注转为通用格式，划分训练、验证、测试集。单独增强小尺寸车辆样本，提升检测灵敏度。

3 交通流量识别准确性影响因素分析

3.1 环境因素对识别准确性的影响

环境因素是影响交通流量识别准确性的关键外部因素，主要包括天气、光照和拍摄环境干扰三类。恶劣天气会降低视频对比度、模糊细节，路面反光和低能见度干扰车辆特征提取，误检、漏检率随之升高。光照变化体现在昼夜交替、强光直射和阴影遮挡，强光导致过曝丢失特征，夜晚光线不足使轮廓模糊，阴影易造成误判，早晚低角度光照的长阴影干扰车辆区域分割。拍摄环境干扰涵盖摄像头抖动、镜头污染和背景复杂，抖动导致帧模糊位移，复杂背景增加目标区分难度，拥堵场景中行人、非机动车与车辆重叠进一步降低统计准确性。

3.2 车辆特征与运动状态的影响

车辆特征与运动状态直接影响检测效果和流量统计准确性。车辆特征上，类型多样性带来外形、尺寸、颜色的较大差异，大型车辆易遮挡小型车辆造成漏检；老旧车辆或携带货物的车辆外形、纹理异常，难以匹配预训练模型，误检率随之增加；拥堵场景中车辆排列密集、重叠率高，检测网络难以分割单个目标，出现计数偏差。运动状态上，高速行驶车辆易产生运动模糊，丢失特征导致识别困难；行驶轨迹变化让目标位置、姿态频繁变动，易出现 ID 切换，造成重复计数或漏计；路口车辆转弯、掉头导致朝向改变，检测网络对不同朝向车辆的特征提取能力不同，侧方行驶车辆识别准确率更低。

3.3 检测模型参数设置的影响

检测模型参数设置直接决定检测性能，影响流量识别准确性，主要涉及网络结构、训练、推理三类参数。网络结构参数里，主干网络选择影响特征提取能力，需结合硬件平衡性能与速度；编码器核心单元扩张率设置至关重要，过小或过大都会影响不同尺寸车辆识别精度；均匀匹配相关参数需合理，避免小尺寸车辆训练不足或引入无效锚点^[4]。训练参数中，学习率初始值与调整策略影响收敛效果，批量大小需匹配硬件，数据增强强度需适中，避免样本失真或增强不足。推理参数里，置信度阈值影响检测结果，需按目标类型合理设置；后处理阈值影响边界框去重，过高或过低都会影响计数准确性。

3.4 硬件资源与实时性约束

硬件资源与实时性约束的平衡，对流量识别准确性有间接但关键影响。硬件上，GPU 计算能力决定推理速度与精度，低性能 GPU 无法支持复杂网络实时推理，易导致帧处理延迟、轨迹断裂和漏计；CPU 性能影响帧的读取、预处理和传输，不足会造成帧堆积，错过检测时机；内存不足限制批量处理规模，降低模型泛化能力。实时性约束上，为满足实时要求，需对模

型轻量化处理，却会降低特征提取能力和准确率；多摄像头视频流并行处理会增加硬件负载，负载不足引发处理延迟，高峰时段偏差更明显；网络延迟导致视频数据传输滞后，检测网络基于过时帧统计，无法反映实时交通状况（见图2）。

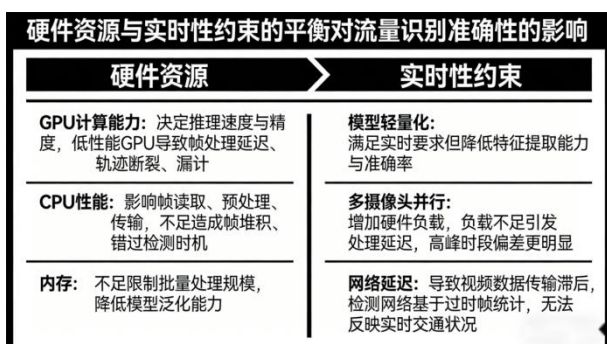


图2 硬件资源与实施性约束的平衡对流量识别的准确性的影响

4 准确性验证实验与结果分析

4.1 实验设计与评价指标确定

实验设计以真实交通场景为核心，构建多维度验证体系，保障结果客观代表性。硬件采用高性能 GPU、CPU 和大容量内存服务器，软件基于主流深度学习框架搭建，结合相关工具包实现训练与推理。实验数据分为两部分：公开数据集用于预训练和基础性能验证，选取车辆相关类别针对性训练；自制真实场景数据集包含多个视频片段，采集于多个路口，涵盖不同天气、光照和交通条件，用于场景适应性验证。实验设置三类对照实验，对比不同检测网络、流量统计方法及模型优化前后的性能。评价指标包含计数准确性和实时性，前者采用常用误差指标并统计各类交通状态准确率，后者采用帧率衡量处理速度。

4.2 不同场景下的准确性对比实验

不同场景下的准确性对比实验，重点验证模型在复杂环境中的适应性，本文融合模型在各类场景中均表现更优。天气场景中，晴朗天气下模型表现最佳，恶劣天气下性能虽有下降，相比其他模型仍有优势，核心模块优化和数据增强策略的适配

提供了支撑。光照场景中，正常光照下性能最优，夜晚低光照和早晚逆光场景下性能下降，相关标准化层和预处理有效缓解了光照对特征提取的影响。交通状态场景中，流畅场景准确性最高，拥堵程度加剧则准确性下降，核心原因是车辆重叠率提高，特定匹配策略有效降低了遮挡漏检率，拥堵场景下优势尤为明显。

4.3 模型优化前后准确性差异分析

模型优化前后准确性对比实验，验证了各核心优化模块的有效性，以基础网络为基准，逐步添加优化模块分析性能变化。仅使用基础网络时，模型性能一般；添加扩张编码器后，性能显著提升，大尺寸车辆识别准确率改善最明显，有效扩大了感受野，覆盖多尺度车辆。在此基础上添加均匀匹配方法，性能进一步提升，小尺寸车辆识别准确率明显改善，验证了对正负锚点平衡的优化作用。优化损失函数后，模型对难样本识别能力增强，整体准确率提升；融合目标跟踪模块后，有效解决遮挡和 ID 切换问题，计数准确性大幅提高，拥堵场景效果突出，各模块逐步完善实现了准确性显著提升。

4.4 与传统检测方法的准确性对标

本文融合模型与传统检测方法进行准确性对标，传统方法包括线圈、超声波和传统视频检测，本文模型准确性全面更优。与线圈检测相比，无需破坏路面安装，可避免车辆间距小时计数准确率低的问题，复杂交通流下更稳定。与超声波检测相比，不受环境噪声影响，对不同类型车辆识别准确性更高，还能获取更丰富的交通信息。与传统视频检测相比，深度学习和多模块融合提升了复杂场景适应性，有效解决传统方法在遮挡、光照变化、车辆尺度差异等情况下的准确性不足问题，交通流量波动大的场景中，计数稳定性和准确性优势更为明显。

5 结语

本文构建融合单级特征检测与优化跟踪策略的视频交通流量检测模型，解决传统方法场景适应性差、遮挡易漏检等问题。实验证明，该模型在不同天气、光照及交通状态下均具备较高计数准确性与实时性。研究明确环境、模型参数、硬件资源对检测效果的作用机制，为模型轻量化与工程部署提供参考。

参考文献:

- [1] 吴文静,章培军.基于 YOLOv5 的车流量检测研究[J].现代计算机,2024,30(12):24-27.
- [2] 马庆禄,吴跃川,张梓轩,等.面向车流量智能检测的 YOLOv7 算法改进与应用[J].公路,2024,69(01):242-249.
- [3] 刘伟.基于深度学习的空基平台交通流量采集方法[D].华北理工大学,2023.
- [4] 朱光亚.基于边缘计算的交通流量检测方法研究与实现[D].西北师范大学,2023.