

# 基于冲击波模型与YOLOv5-DeepSORT单向耦合的排队长度感知方法

王佳如<sup>1</sup>, 吕斌<sup>1\*</sup>, 吴建清<sup>2</sup>, 王志勇<sup>1</sup>

(1.兰州交通大学交通运输学院, 甘肃 兰州 730070; 2.山东大学齐鲁交通学院, 山东 济南 250002)

**摘要:**针对交叉口排队长度实时感知的问题,提出一种结合交通数学模型与智能感知设备检测的排队长度感知方法。通过冲击波模型确定道路最大排队长度,将其作为以YOLOv5-DeepSORT为基础的视频感知模型的输入,实现交通数学模型与智能感知模型的单向耦合。为验证该方法的有效性和优越性,以兰州市某交叉口为例进行排队长度的实时感知,并在选定交叉口调查不同时间段的感知数据,模拟不同交叉口交通流量的差异对本研究方法感知精度的影响进行探究。研究表明,基于冲击波模型与YOLOv5-DeepSORT单向耦合的排队长度感知方法确定的排队长度检测区域在整体感知精度上优于对照组,平均绝对误差、均方根误差以及平均绝对百分比误差等均得到了有效降低,部分工况下精度提高40%以上。

**关键词:**智能交通系统;排队长度;视频检测;冲击波模型;YOLOv5-DeepSORT

中图分类号:U491.8

文献标志码:A

**引用格式:**王佳如,吕斌,吴建清,等.基于冲击波模型与YOLOv5-DeepSORT单向耦合的排队长度感知方法[J].山东大学学报(工学版),2024,54(5):42-49.

WANG Jiaru, LÜ Bin, WU Jianqing, et al. Queue length perception method based on one-way coupling between shockwave model and YOLOv5-DeepSORT[J]. Journal of Shandong University (Engineering Science), 2024, 54(5):42-49.

## Queue length perception method based on one-way coupling between shockwave model and YOLOv5-DeepSORT

WANG Jiaru<sup>1</sup>, LÜ Bin<sup>1\*</sup>, WU Jianqing<sup>2</sup>, WANG Zhiyong<sup>1</sup>

(1. School of Traffic and Transportation, Lanzhou Jiaotong University, Lanzhou 730070, Gansu, China; 2. School of Qilu Transportation, Shandong University, Jinan 250002, Shandong, China)

**Abstract:** For the real-time perception of queue lengths at intersections, a method was proposed that combined traffic mathematical models with intelligent perception devices for queue length detection. The method determined the maximum queue length of the road using shock wave models, which served as input for a video perception model based on YOLOv5-DeepSORT, to achieve unidirectional coupling between traffic mathematical models and intelligent perception models. To validate the effectiveness and superiority of this method, real-time queue length perception was conducted at a specific intersection in Lanzhou City. Perception data from different time periods at the selected intersection were investigated to explore the impact of varying traffic flow on the perception accuracy of this method. The research findings indicated that the queue length detection area determined by the queue length perception method based on shock wave models and YOLOv5-DeepSORT unidirectional coupling outperformed the control group in overall perception accuracy. Significant improvements were observed in metrics such as mean absolute error, root mean square error, and mean absolute percentage error, with an increase in accuracy of over 40% in certain scenarios.

**Keywords:** intelligent transportation system; queue length; video detection; shockwave model; YOLOv5-DeepSORT

收稿日期:2023-12-18

**基金项目:**国家自然科学基金资助项目(52362044);甘肃省教育厅双一流重大科研资助项目(GSSYLXM-04);山东省重点研发计划(重大科技创新工程)(2020CXGC010118)

**第一作者简介:**王佳如(1999—),女,宁夏吴忠人,硕士研究生,主要研究方向为智慧交通。E-mail:jiaruwang3233@163.com

**\*通信作者简介:**吕斌(1975—),男,甘肃兰州人,教授,博士生导师,博士,主要研究方向为智慧交通。E-mail:jdlbxx@mail.lzjtu.cn

## 0 引言

在智能交通系统中,信号控制交叉口的车辆排队长度是衡量城市路网服务水平的关键指标。排队长度的可解释性强,并且与交叉口车辆延误指数、停车次数和行驶时间等重要指标高度相关,可以较精准地反映城市道路的交通状态,有助于更准确地评估交叉口信控系统的性能,为交叉口的管理和优化提供数据支撑<sup>[1-2]</sup>。

目前,对交叉口排队长度的感知方法主要有交通数学模型估计法和基于传感器的智能感知方法<sup>[3-4]</sup>。交通数学模型估计法,主要有输入输出模型和冲击波模型2种。输入输出模型通过对交叉口累计交通量的输入和输出进行车辆排队分析,但是由于其无法获得车辆队列在时间上的空间分布,只适用于估计队列长不超过固定检测器所在位置的短队列<sup>[5-6]</sup>;基于交通流理论的冲击波模型本质上是通过固定检测器提供的车辆轨迹信息估计信号周期内的最大队列长度,适用于干线道路交通量大、排队长的情况<sup>[7-9]</sup>。尽管学者们对于交通数学模型估计法做了大量研究,但是由于侧重点和检测手段不同,这类方法实时性不强,难以刻画排队状态的实时变化。随着交通感知设备和感知技术的快速发展,基于雷达、摄像头以及多源数据融合的智能排队感知方法引起了越来越广泛的关注<sup>[10-13]</sup>,其中,摄像头在城市道路交通感知中应用广泛,且视频数据语义丰富,在识别车辆排队长度上具有很大优势。早期基于视频数据的排队感知研究中,主要使用传统的计算机视觉检测方法,包括基于目标特征检测、基于移动检测窗和基于复式检测窗的方法等<sup>[14-16]</sup>。这类方法往往需要精准的摄像头标定,灵活性差,而且计算复杂,难以满足实时排队长度的感知需求。目前,基于深度学习的视觉感知方法弥补了传统方法的诸多缺陷,在智能交通感知领域已经得到广泛应用<sup>[17-19]</sup>,然而,这类方法在车辆排队感知的相关研究中应用的还比较少。文献<sup>[20]</sup>设计了一种基于卷积神经网络的排队长度估计方法,通过检测每个车道的停车数量判断排队长度,为了便于计算,没有区分车型,也没有考虑车辆全排队过程中行驶特征的变化,虽然方法简单易行,但是检测的误差比较大,存在一定的改进空间。

综上所述,基于交通数学模型的方法有较多天然的缺陷,而基于视频数据的排队长度感知方法对

于排队车辆的种类、状态考虑相对较少,大多数对排队长度的感知方法较为粗糙,同时在感知精度方面还有一定的提升空间。针对这一问题,本研究提出一种基于视频数据的排队长度感知方法,旨在提升方法感知精度和解决模型实时性问题。本研究方法以YOLOv5-DeepSORT为基础检测模型,分车道感知具备排队特征的车辆,根据分车型的排队长度计算各车道的排队长度。综合考虑模型对小目标检测造成的误差和排队长度的感知范围要求,通过冲击波模型与YOLOv5-DeepSORT模型单向耦合的方式设计合理的感知范围,在保证检测精度的同时也对车辆排队行为进行全面感知。

## 1 方法概述

图1为基于冲击波与YOLOv5-DeepSORT单向耦合的排队长度感知方法流程图,主要分为两部分:(1)通过交通数学模型预测最大排队长度;(2)将上一步的最大排队长度作为基于视频数据的智能感知模型输入,为模型划分最优感知区域,通过YOLOv5-DeepSORT检测区域内目标车辆的行驶特征,从而判断行驶状态计算排队长度。

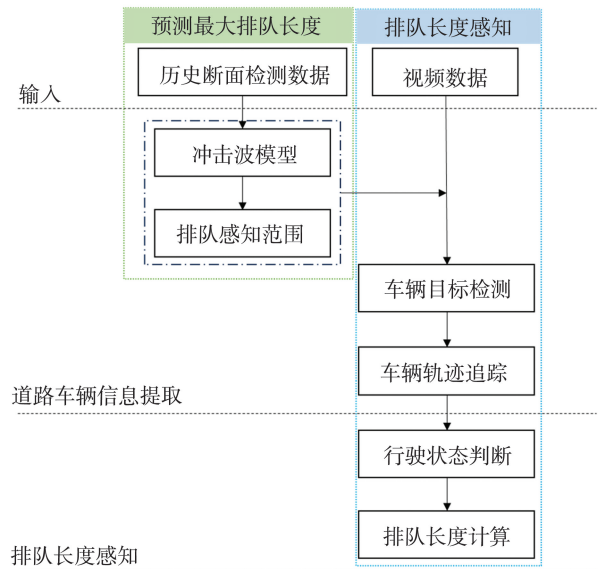



图1 本研究方法流程图  
Fig.1 Flowchart of the method


## 2 基于冲击波模型的感知区域预测

车辆排队长度预测冲击波模型中,由于车辆之间的互动效应,假设车辆密度的突然变化会导致一波“冲击”向下游传播。当流量增大时,排队长度可能会增加,而冲击波模型能够刻画这种流量变化引


起的拥堵扩散,如图2所示,图中 $t$ 为时间, $D$ 为距离。



(a) 排队累积冲击波



(b) 排队消散冲击波



(c) 排队压缩冲击波

图2 冲击波模型示意图

Fig.2 Shockwave model diagram

图2(a)描述了排队累积冲击波的形成过程,假设前一周期的队列已排空,排队在当前周期红灯开

始时累积,道路上的交通流由自由流状态向阻塞流状态转变;图2(b)描述了排队消散冲击波形成,随着排队累积冲击波向交叉口上游传播,直至信号灯绿灯开启时,队列前方车辆开始以饱和流速排放;图2(c)描述了当累积冲击波和消散冲击波相遇时,形成交叉口当前周期的最大排队长度。此时,道路上的交通流开始由饱和流逐步向自由流转变,从而产生排队压缩冲击波。

冲击波模型<sup>[3]</sup>预测一个信号周期内的最大排队长度 $L_m$ ,具体公式为:

$$L_m = L_d + (T_C - T_B) / \left( \frac{1}{u_2} + \frac{1}{u_3} \right), \quad (1)$$

式中, $L_d$ 为检测器到停车线的距离, $T_B$ 、 $T_C$ 分别为断点B、C处的时间, $u_2$ 、 $u_3$ 分别为排队消散波和压缩波的波速。其中, $T_B$ 、 $T_C$ 、 $u_2$ 和 $u_3$ 都可以通过交叉口布设的固定检测器检测到的轨迹数据得到或计算。

### 3 基于视频数据的排队长度感知模型

#### 3.1 目标检测追踪算法

对车辆行驶轨迹的追踪是排队长度感知的基础。在目标检测追踪算法中,进行运算需要输入目标物的位置和分类信息等。YOLOv5作为单阶段端到端的目标检测算法之一,实时性好,检测精度较高,因此,本研究选择YOLOv5-m作为排队长度感知方法中目标检测模块的基础模型。文献[21]提出的多目标跟踪算法DeepSORT利用运动模型和目标外观信息进行数据关联,通过检测目标并根据其边界框的位置、大小和运动信息进行跟踪定位。DeepSORT算法为减少在遮挡后出现身份跳变的情况使用了外观特征区分目标,而YOLOv5目标检测模型具有高效的实时目标检测能力,可以提取高维度的特征向量表示目标外观信息。通过将YOLOv5检测到的目标和它们的特征向量传递给DeepSORT算法,使用这些特征向量跟踪物体,并尝试将它们关联到先前帧中已知的轨迹上,能够提高系统的检测和跟踪能力,有效实现实时跟踪和定位运动车辆,为车辆排队状态的感知提供检测基础。

#### 3.2 基于YOLOv5-DeepSORT的排队长度感知模型

通过YOLOv5-DeepSORT轨迹追踪模型得到车辆类型和检测框的实时位置坐标后,建立排队长

度感知模型。根据实际车道确定实时排队长度感知区域,对视频中的车辆按车道分类。感知区域设置如图3所示,黄色阴影区域表示直行车道的排队感知区域,蓝色阴影部分表示直左车道的排队感知区域。



图3 感知区域设置示意图

Fig.3 Perceptual region configuration diagram

车辆进入不同车道的感知区域,其编号纳入相应车道的车辆集合,当车辆驶出画面,则删除集合中对应的编号。通过每个车道的车辆集合,可以判断该车道当前的车辆排队情况。

车辆排队长度的实时感知能够反映排队累积-消散的动态排队过程。在以往的研究中,常以车辆速度为0时的队列长度作为检测目标。但是,实际排队车辆的队列中总有一部分或全部车辆以微小的速度移动,特别是在交通量大的交叉口。因此,为保证感知精度,本研究将车速低于交叉口正常行驶最低速度的车辆视为处于排队状态,该速度需要根据实际交叉口排队中的车辆行驶特征设定。由于视频数据的二维特性,一般在速度检测时需要根据不同的数据进行标定,降低了检测模型的普适性。因此,本研究选择车辆单位时间内移动的像素距离作为判断是否排队的指标。针对视频画面的透视问题,因为车辆的检测框会随车辆图像面积的增大而增大,因此最终以车辆单位时间内移动的像素距离与检测框底边像素长度的比值为判断依据,即

$$e=l/w, \quad (2)$$

式中: $e$ 为检测指标; $l$ 为车辆单位时间内移动的像素距离,本研究用第 $p$ 帧目标检测框的中心点 $(o_x^p, o_y^p)$ 到第 $f$ 帧目标检测框中心点 $(o_x^f, o_y^f)$  $w$ 为当前帧车辆检测框底边像素长度。将式(1)展开为:

$$\begin{cases} e = \sqrt{(o_x^p - o_x^f)^2 + (o_y^p - o_y^f)^2} / w \\ o_x^n = (z_x^n + c_x^n) / 2 \\ o_y^n = (z_y^n + c_y^n) / 2 \\ w = z_x^f - c_x^f \end{cases}, \quad (3)$$

式中, $(o_x^n, o_y^n)$ 为第 $n$ 帧中目标检测框中心点的坐标, $(c_x^n, c_y^n)$ 为目标检测框左上角的坐标, $(z_x^n, z_y^n)$ 为目标检测框右下角的坐标, $z_x^f$ 为第 $f$ 帧目标检测框右下角顶点的横坐标, $c_x^f$ 为第 $f$ 帧目标检测框左上角顶点的横坐标。当目标车辆以正常行驶的最低速度 $v_0$ 行驶时,对应的检测指标 $e$ 为 $e_0$ 。

通过式(3),结合视频数据可以得到目标车辆的检测指标 $e$ ,通过比较 $e$ 与 $e_0$ 的大小判断目标车辆是否处于排队状态,即当 $e < e_0$ 时,车辆为排队状态,此时逻辑变量 $\alpha = 1$ ,否则为0。

车辆排队长度

$$L = \sum_{i=1}^k h_i \alpha_i, \quad (4)$$

式中, $i$ 表示车辆序号, $h_i$ 表示车辆 $i$ 对应车型的车辆长度, $\alpha_i$ 表示车辆 $i$ 是否处于排队状态。

## 4 方法测试与验证

不同交叉口的交通流量、渠化设计、信号控制方案和车型比例等因素有所差异,车辆队列的平均长度也不相同,进而影响本研究方法的感知精度。本研究通过选择同一路口不同时间段的感知数据,模拟不同路口交通流量的差异对模型感知精度的影响,从而验证模型的有效性。以甘肃省兰州市酒泉路-甘南路交叉口南进口为实际应用案例,南进口方向有3个车道,分别为直行车道,直右车道和直左车道,如图4所示。由于右转车流量不大,排队情况较少,直行车道和直左车道排队情况基本一致,因此主要用直行车道进行模型的相关数据测试。



图4 酒泉-甘南路交叉口示意图

Fig.4 Jiuquan-Gannan Road diagram

为求出该进口处全天最大排队长度,本研究选取15个工作日的早晚高峰时段排队情况进行对比,最大排队车辆统计如图5所示。由图5可知,早高峰的最大排队车辆数整体高于晚高峰时

段,因此选择早高峰时段某一信号周期内的车辆最大排队长度作为该车道一天内的车辆最大排队长度。




图5 早晚高峰最大排队车辆统计

Fig.5 The statistical chart of the maximum queued vehicles during morning and evening rush hours

本研究选取早高峰车流量最大时段一个信号周期内的车辆检测数据进行分析。通过1.1节中的冲击波模型计算可得该车道早高峰时段的最大排队长度为68.88 m。根据文献[3],冲击波模型预测的排队长度平均绝对百分比误差为7%,因此将排队长度车辆检测范围设置为0~74 m,即模型预测区域。同时,为验证感知方法的可靠性,采用文献[20]中的排队长度感知方法设置2组对比试验,将其感知范围的上限分别移至模型预测区域10 m处,3组试验检测区域设置如图6所示。



图6 检测范围设置示意图

Fig.6 Schematic diagram of detection range configuration

速度阈值 $v_0$ 受到所感知交叉口的交通状况影响,为了得到该交叉口的速度阈值,本研究根据该交叉口的车辆速度绘制交叉口信号周期-车辆速度散点图,如图7所示,图7中 $T$ 为一个信号周期,绿色区域表示绿灯时段,红色区域表示红灯时段。根据图7中车辆的速度分布,并结合车辆的排队行为,得到该交叉口的 $v_0$ 约为5 km/h,与文献[22]中所设定的速度阈值基本一致。




图7 T-v散点图

Fig.7 T-v scatter plot

本研究根据交叉口交通量的差异,将感知数据分为3组,即早高峰时段、晚高峰时段和平峰时段。为了使视频数据的选取更具有一般性,随机选取该车道约32个周期的视频数据进行检测,并将检测结果与实地观测的实际结果进行对比。以平均绝对误差(mean absolute error, MAE) $E_{MA}$ 、均方根误差(root mean square error, RMSE) $E_{RMS}$ 和平均绝对百分比误差(mean absolute percentage error, MAPE) $E_{MAP}$ 作为感知方法的性能指标,计算公式分别为:

$$E_{MA} = \frac{\sum_{j=1}^g |\hat{z}_j - z_j|}{g}, \quad (5)$$

$$E_{RMS} = \sqrt{\frac{\sum_{j=1}^g (\hat{z}_j - z_j)^2}{g}}, \quad (6)$$

$$E_{MAP} = \frac{100\% \cdot \sum_{j=1}^g \left| \frac{\hat{z}_j - z_j}{z_j} \right|}{g}, \quad (7)$$

式中, $g$ 是检测结果的总量, $\hat{z}_j$ 是第 $j$ 个检测排队长度, $z_j$ 是第 $j$ 个实际排队长度。检测结果如图8所示。

不同方法性能对比的具体结果如表1所示。

由图8和表1可得:

(1)从对照组与本研究模型感知精度的对比可以看出,当感知区域选择过长或者过短都会导致精度降低,由此也验证了本研究对感知区域距离判断的正确性。当距离过远时,误差较大的主要原因可归结为:①排队感知范围增大后,模型对于远距离小目标的检测精度下降。②由于距交叉口较远,车辆换道行为较多,也会影响排队长度的检测精度;当距离较近时,受到检测范围的限制,检测到的排队长度整体低于实际长度,由于超出检测范围的队列较多,因此检测结果误差较大。

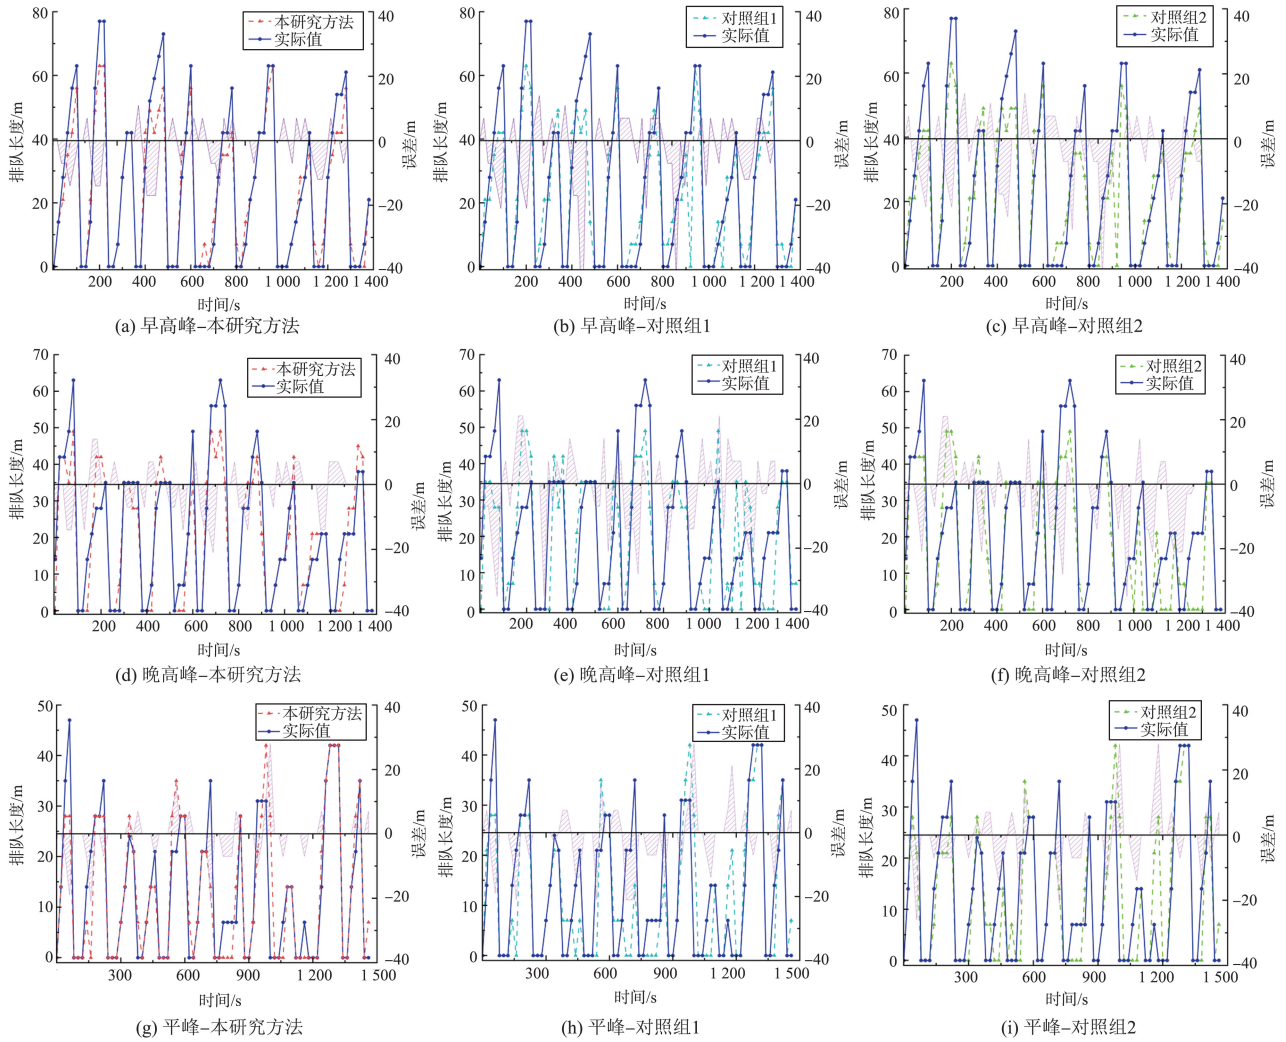


图8 排队长度检测结果  
Fig.8 Queue length detection results

表1 不同方法感知精度对比

Table1 Comparison of perception accuracy among different methods

时段	模型	$E_{MA}$	$E_{RMS}$	$E_{MAP}/\%$
早高峰	对照组 1	7.30	11.95	8.20
	对照组 2	7.04	10.50	8.13
	本研究模型	4.24	6.68	4.81
晚高峰	对照组 1	8.89	12.19	8.62
	对照组 2	7.39	11.14	6.16
	本研究模型	4.86	7.40	5.77
平峰	对照组 1	5.39	8.98	5.01
	对照组 2	4.97	8.55	5.40
	本研究模型	3.24	6.59	3.97

(2) 在早高峰时段,基于冲击波模型与YOLOv5-DeepSORT排队感知模型的单向耦合方法,冲击波模型确定的排队长度检测区域使模型整体检测精度优于两对照组。平均绝对误差、均方根误差以及平均绝对百分比误差分别为4.24 m、6.68 m和4.81%,远高于单一冲击波模型和未经感

知范围筛选的YOLOv5-DeepSORT排队长度感知模型精度。相较于未经感知范围筛选的YOLOv5-DeepSORT模型,即对照组1和2,本研究方法平均绝对误差、均方根误差以及平均绝对百分比的精度最大分别可提高42%、44%以及41%。由此可见,本研究建立的模型大幅提高了感知精度,可以为交叉口交通运行效率评价和交通信号控制提供模型及数据支撑。

(3) 在晚高峰时段,本研究模型检测的平均绝对误差、均方根误差以及平均绝对百分比误差分别为4.86 m、7.40 m以及5.77%,相较于对照组1和2精度最大分别可提高45%、39%以及33%。

(4) 在平峰时段,本研究模型的检测平均绝对误差、均方根误差以及平均绝对百分比误差分别为3.24 m、6.59 m以及3.97%,相较于对照组1和2精度最大分别可提高40%、27%以及26%。相对于早晚高峰,本研究模型在平峰时段优越性有所降低,主要是因为平峰时段,车流量较小对检测区域的

设定要求不高,因此3组测试对平峰时段的检测性能都相对较好。

通过以上对比,本研究方法可直接判定感知区域,无论在车流量较大的早晚高峰,还是在车流量较小的平峰时段,本研究模型相较于文献[20]中未经感知范围筛选的YOLOv5-DeepSORT模型展现出了一定的优越性和稳定性。同时,与文献[3]中提出的传统交通数学模型相比,精度显著提升。

## 5 结论

本研究提出一种基于冲击波模型与YOLOv5-DeepSORT单向耦合的排队感知方法。该方法首先通过冲击波模型确定道路最大排队长度,将其作为以YOLOv5-DeepSORT为基础的视频感知模型的输入,实现交通数学模型与智能感知模型的单向耦合。该方法通过车辆排队冲击波模型从微观层面分析信控交叉口队列形成和消散的过程,利用交叉口历史车流数据估计最大排队长度,确定车道检测模块位置坐标。根据YOLOv5-DeepSORT算法追踪车辆轨迹,对车辆目标划分车道,判断各车道上的车辆是否处于排队状态。最后,通过兰州市的一个实际信号控制交叉口对方法的有效性和优越性进行验证,得到以下主要结论。

(1)本研究方法可直接判定感知区域,而未经感知范围筛选的YOLOv5-DeepSORT模型感知精度与感知区域的选择有关,因此本研究的方法相较于未经感知范围筛选的YOLOv5-DeepSORT模型稳定性更佳。除此以外,从对照组与本研究方法感知精度的对比可以看出,当感知区域选择过长或者过短都会导致精度降低,由此也验证了本研究对感知区域距离判断的正确性。

(2)本研究方法无论在车流量较大的早晚高峰,还是在车流量较小的平峰时段,相较于未经感知范围筛选的YOLOv5-DeepSORT模型都展现出一定的优越性。本研究方法能大幅提高感知精度,部分工况下甚至能提高精度40%以上。该方法的建立可为交叉口交通运行效率评价和交通信号控制提供模型及数据支撑。

本研究仍存在一定的不足。受到试验条件限制,没有在多个交叉口对本研究提出的模型进行对比验证,不同的感知场景和交通流情况都会对该模型的性能产生一定影响。例如,交叉口车辆到达率的随机性、一天中的时间和恶劣天气导致的能见度下降都可能影响到模型的检测精度。随着图像目

标检测模型迭代更新的速度不断加快,检测精度不断提高。未来,针对现有模型对远处小目标检测精度较低的问题,可以使用YOLOv9等性能更优的基础目标检测模型,也可以考虑动态调整检测区域,适应路口的排队长度,使得感知方法更准确。

### 参考文献:

- [1] 吴建清, 宋修广. 智慧公路关键技术发展综述[J]. 山东大学学报(工学版), 2020, 50(4): 52-69.  
WU Jianqing, SONG Xiuguang. Review on smart highways critical technology [J]. Journal of Shandong University (Engineering Science), 2020, 50(4): 52-69.
- [2] 周晓昕, 廖祝华, 刘毅志, 等. 融合历史与当前交通流量的信号控制方法[J]. 山东大学学报(工学版), 2023, 53(4): 48-55.  
ZHOU Xiaoxin, LIAO Zhuhua, LIU Yizhi, et al. Signal control method integrating history and current traffic flow [J]. Journal of Shandong University (Engineering Science), 2023, 53(4): 48-55.
- [3] LIU H X, WU X, MA W, et al. Realtime queue length estimation for congested signalized intersections [J]. Transportation Research Part C: Emerging Technologies, 2009, 17(4): 412-427.
- [4] 施康, 杨晓光, 王一喆. 基于数据的交叉口车辆排队状态感知方法研究[J]. 公路交通科技, 2022, 39(1): 114-119.  
SHI Kang, YANG Xiaoguang, WANG Yizhe. Study on vehicle queuing state perception method at intersection based on data[J]. Journal of Highway and Transportation Research and Development, 2022, 39(1): 114-119.
- [5] YI P, TIAN Z Z, ZHAO Q. Consistency of input-output model and shockwave analysis in queue and delay estimations[J]. Journal of Transportation Systems Engineering and Information Technology, 2008, 6(8): 146-152.
- [6] VIGOS G, PAPAGEORGIOU M, WANG Y. Real-time estimation of vehicle-count within signalized links [J]. Transportation Research Part C: Emerging Technologies, 2008, 16(1): 18-35.
- [7] 羊钊, 刘攀, 朱仁伟, 等. 基于冲击波理论的信号交叉口最大广义排队长度计算方法[J]. 长安大学学报(自然科学版), 2015, 35(增刊1): 154-159.  
YANG Zhao, LIU Pan, ZHU Renwei, et al. Estimation of the maximum queue length at signalized intersections based on shockwave theory[J]. Journal of Chang'an University (Natural Science Edition), 2015, 35 (Suppl. 1): 154-159.
- [8] ZHAN X, LI R, UKKUSURI S V. Lane-based realtime queue length estimation using license plate recognition

- data [J]. *Transportation Research Part C: Emerging Technologies*, 2015, 57: 85-102.
- [9] PUDASAINI P, KARIMPOUR A, WU Y J. Realtime queue length estimation for signalized intersections using single-channel advance detector data [J]. *Transportation Research Record*, 2023, 2677(7): 144-156.
- [10] WU J, XU H, ZHENG Y, et al. A novel method of vehicle-pedestrian near-crash identification with roadside LiDAR data[J]. *Accident Analysis & Prevention*, 2018, 121: 238-249.
- [11] WU J, XU H, TIAN Y, et al. An automatic lane identification method for the roadside light detection and ranging sensor[J]. *Journal of Intelligent Transportation Systems*, 2020, 24(5): 467-479.
- [12] 连丽容, 罗文婷, 秦勇, 等. 双目机器视觉及RetinaNet模型的路侧行人感知定位[J]. *中国图象图形学报*, 2021, 26(12):2941-2952.
- LIAN Lirong, LUO Wenting, QIN Yong, et al. Roadside pedestrian detection and location based on binocular machine vision and RetinaNet [J]. *Journal of Image and Graphics*, 2021, 26(12):2941-2952.
- [13] TIAPRASERT K, ZHANG Y, WANG X B, et al. Queue length estimation using connected vehicle technology for adaptive signal control [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(4): 2129-2140.
- [14] 吴浩, 刘磊, 唐克双. 基于集成学习的信号控制交叉口排队长度估计[J]. *同济大学学报(自然科学版)*, 2023, 51(3):405-415.
- WU Hao, LIU Lei, TANG Keshuang. Queue length estimation at signalized intersection based on ensemble Learning [J]. *Journal of Tongji University (Natural Science)*, 2023, 51(3):405-415.
- [15] ZANIN M, MESSELODI S, MODENA C M. An efficient vehicle queue detection system based on image processing[C]//12th International Conference on Image Analysis and Processing (ICIAP). Mantova, Italy: IEEE, 2003: 232-237.
- [16] ZHU L, KHORAMSHAHI E, TURPPA T, et al. Traffic queue length measurement by using combined methods of Photogrammetry and digital image processing[C]//2015 Joint Urban Remote Sensing Event (JURSE). Lausanne, Switzerland: IEEE, 2015: 1-4.
- [17] 余志, 黄柳红, 李熙莹, 等. 基于视频的交叉口排队过程感知及预测[J]. *交通运输系统工程与信息*, 2020, 20(1):33-39.
- YU Zhi, HUANG Lihong, LI Xiyang, et al. Queueing process sensing and prediction at intersection based on video[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2020, 20(1):33-39.
- [18] 宋士奇, 朴燕, 蒋泽新. 基于改进YOLOv3的复杂场景车辆分类与跟踪[J]. *山东大学学报(工学版)*, 2020, 50(2):27-33.
- SONG Shiqi, PIAO Yan, JIANG Zexin. Vehicle classification and tracking for complex scenes based on improved YOLOv3[J]. *Journal of Shandong University (Engineering Science)*, 2020, 50(2):27-33.
- [19] 毛昭勇, 王亦晨, 王鑫, 等. 面向高速公路的车辆视频监控分析系统[J]. *西安电子科技大学学报*, 2021, 48(5):178-189.
- MAO Zhaoyong, WANG Yichen, WANG Xin, et al. Vehicle video surveillance and analysis system for the expressway[J]. *Journal of Xidian University*, 2021, 48(5):178-189.
- [20] UMAIR M, FAROOQ M U, RAZA R H, et al. Efficient video-based vehicle queue length estimation using computer vision and deep learning for an urban traffic scenario[J]. *Processes*, 2021, 9(10): 1786.
- [21] WOJKE N, BEWLEY A, PAULUS D. Simple onlyne and realtime tracking with a deep association metric [C]//2017 IEEE International Conference on Image Processing (ICIP). Beijing, China: IEEE, 2017: 3645-3649.
- [22] TAN C, YAO J, TANG K, et al. Cycle-based queue length estimation for signalized intersections using sparse vehicle trajectory data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 22(1): 91-106.

(编辑:郭少华)