

DOI: 10.19650/j.cnki.cjsi.J2412992

基于计算机视觉的城市道路噪声实时估计*

李响^{1,2}, 张琰霖¹, 李国正³, 赖本涛¹, 陈梦君¹

(1. 华东交通大学交通运输工程学院 南昌 330013; 2. 江西开放大学 南昌 330046;
3. 北京交通大学机械与电子控制工程学院 北京 100044)

摘要: 为了实现城市道路视频监控场景下交通流噪声的快速准确估计, 提出一种基于计算机视觉的城市道路噪声实时估计方法。首先, 从道路交通噪声产生机理分析入手, 提出了一系列基于计算机视觉的城市道路交通噪声相关交通流信息提取方法, 改善传统方法提取交通流信息不够便捷的情况。其次, 针对传统算法噪声估计准确度不高的问题, 进行城市道路交通噪声影响因素分析, 将交通流特征与环境特征相结合, 构建了基于机器学习的道路交通噪声估计模型, 提高了城市道路噪声估计的准确性。最后, 分析城市道路交通噪声短时变化规律, 确定其尺度可变的特征提取时间窗口, 提出了一整套城市道路交通噪声实时估计方案, 提升了城市道路噪声估计的实时性。实验结果表明, 所提出的基于计算机视觉的交通流信息提取方法较常用的目标检测和跟踪算法能够更准确的提取城市道路交通噪声相关信息; 所建立的城市道路交通噪声估计模型相比传统噪声估计模型有更高的实时性和准确性, 相较于现有基于机器学习的噪声估计方法在不同场景下均有着更为准确的估计结果, 提高了城市道路噪声估计的准确性和实时性, 确定了时间尺度为 3 和 10 min 的噪声估计方法, 具有实际应用价值。

关键词: 计算机视觉; 交通噪声; 特征提取; 噪声估计; 机器学习

中图分类号: TP391.41 TH702 **文献标识码:** A **国家标准学科分类代码:** 510.40

Real-time estimation of urban road noise based on computer vision

Li Xiang^{1,2}, Zhang Ailin¹, Li Guozheng³, Lai Bentao¹, Chen Mengjun¹

(1. School of Transportation Engineering, East China Jiaotong University, Nanchang 330013, China;
2. Jiangxi Open University, Nanchang 330046, China; 3. School of Mechanical, Electronic and Control
engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: To achieve rapid and accurate estimation of traffic noise in urban road video surveillance scenarios, a real-time noise estimation method based on computer vision is proposed. First, starting with an analysis of the mechanisms behind road traffic noise, a series of computer vision-based methods for extracting traffic flow information related to urban road noise are introduced, improving the convenience of traditional methods for extracting traffic flow data. Secondly, to address the low accuracy of traditional noise estimation algorithms, an analysis of the factors influencing urban road traffic noise is conducted. By combining traffic flow features with environmental factors, a machine learning-based model for traffic noise estimation is developed, enhancing the accuracy of urban road noise estimation. Finally, the short-term variation patterns of urban road traffic noise are analyzed, and a variable-scale feature extraction time window is determined. A complete real-time noise estimation solution is proposed, improving the real-time performance of noise estimation. Experimental results show that the proposed computer vision-based traffic flow information extraction method outperforms commonly used object detection and tracking algorithms in accurately extracting traffic noise-related information. The developed model for traffic noise estimation offers better real-time performance and accuracy compared to traditional models and provides more accurate estimates in various scenarios compared to existing machine learning-based noise estimation methods. The noise estimation methods with time scales of 3 and 10 minutes are validated, demonstrating practical application value.

Keywords: computer vision; traffic noise; feature extraction; noise estimation; machine learning

0 引言

汽车数量激增导致的道路交通噪声污染已成为无法忽视的问题^[1],并由此引发听觉障碍、心血管疾病、精神问题等一系列疾病^[2]。为实现快速及时的噪声管控,改善城市声环境质量,提升居民生活水平,首要任务是获取准确实时的噪声值,判断不同交通状况对噪声的影响,进而方便城市的环境保护等相关部门在科学数据的基础上制定有效的噪声控制措施^[3]。目前城市道路噪声检测方法主要有2种,分为直接测量法^[1]与间接估计法^[3]。

直接测量法是指在各个道路的指定位置^[1]安装噪声声级计,直接测量城市道路交通噪声值。该方法大范围普及及声级计成本较高^[4],并且容易受到异常噪声事件的影响^[5],从而干扰道路交通噪声测量准确性。

间接估计法则是通过分析交通噪声产生机理,采用车辆类型、车流量和车速等噪声相关信息,建立噪声估计模型^[3]进行道路交通噪声估计,其优势是:1)能够明确城市道路交通信息与道路交通噪声的关系,为道路交通噪声管控提供理论依据;2)实施简单且具有较好的可移植性^[4]。传统噪声估计模型采用多元线性回归方法^[6];随着计算科学技术的发展,部分研究通过使用BP神经网络(back propagation neural network, BPNN)^[7]、支持向量回归(support vector regression, SVR)^[8]等机器学习技术将车辆类型、车流量、车速和天气等因素进行训练,得到的道路噪声模型估计效果优于传统模型。

然而,现有道路噪声估计研究在实际应用时难以同时满足噪声估计的便捷性、准确性与实时性要求,其难点和挑战具体体现在以下3个方面:1)目前尚未有一整套自动化的城市道路交通噪声相关交通流信息采集方案。现有噪声估计方法通过人工实地采集车型、车流量、车速等噪声相关的信息,此类方法信息采集不够便捷,人工成本和设备成本高昂。2)现有道路交通噪声估计方法考虑噪声相关变量不够充分,准确性仍有改善空间,其忽略了非机动车在机动车道上行驶的情况,且时间、位置、气温、风速和路面等信息也会综合作用影响噪声的产生,需要纳入影响因素范畴。3)传统噪声估计模型存在实时性低,灵敏度差等问题,在实际应用中效果不够理想。传统噪声估计模型为提高估计准确性,通常估计1 h内噪声均值,而忽视了噪声在短时间内的动态变化,比如车流高峰时噪声的短时波动,不能反映噪声的短时峰值和谷值。

为了解决上述问题,考虑到在现代城市交通管理体系中,道路监控设备广泛普及,可以将道路交通监控视频与计算机视觉前沿理论和人工智能先进算法结合,以实现从视频图像中快速准确获取车辆类型、车流量和车速等噪声相关交通流信息,无需增加硬件支出成本,提升交

通流信息采集的效率。

为此,提出一种基于计算机视觉的城市道路交通噪声实时估计方法。该方法采用计算机视觉算法获取城市道路交通噪声相关交通流信息,结合环境等信息采用机器学习算法实现噪声估计。最终在实际的城市道路场景下验证该方法的可行性和有效性。

1 基于计算机视觉的交通流信息提取

噪声相关交通流信息提取是实现城市道路监控场景下交通流噪声快速准确估计的基础和关键性任务。根据监控视频中所记录的不同视角、天气和光照下的城市道路实况画面部分如图1所示,其中包含的城市道路噪声相关的交通流信息^[3]有车辆类型、车流量、车速等。车辆类型识别容易受到拍摄视角、光照和天气变化的影响;车流量可能因车辆遮挡、多车辆交叉和长时间停车等情况而统计不准;车辆测速因视频图像畸变、物体扭曲而误差较大。上述情况给交通流信息提取带来了挑战。此外,参考有关城市道路交通噪声估计的文献^[3,6],研究中选取时间、位置、天气状况、风速和路面类型等噪声相关环境信息作为特征变量。

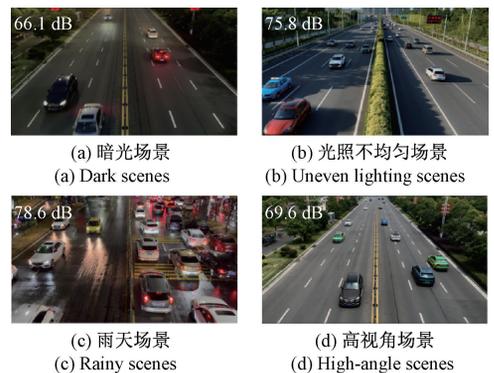


图1 复杂环境下交通流信息

Fig. 1 Complex environment traffic flow information

1.1 基于YOLOv9目标检测算法的车辆类型信息提取

道路交通监控视频中视角、光照和天气变化,以及同一车辆类型存在尺寸、颜色、形状多样性的问题,增加了对车辆类型检测的难度。

传统方法从图像中提取方向梯度直方图(histogram of oriented gradients, HOG)等特征构建车辆类型特征数据集,使用支持向量机(support vector machine, SVM)等分类器完成分类,该方法识别准确率不高,效率低^[9]。随着人工智能的发展,基于深度学习的目标检测算法发展为两阶段算法(代表算法Faster-RCNN(faster region-based convolutional neural network))^[10]和一阶段算法^[11](代表算法YOLO(you only look once)系列)两类,为能够准确

提取车辆类型信息,选用单目标检测算法 YOLOv9^[11] 作为检测器的基础算法,该算法相较于两阶段算法具有检测速度快、高效率的优点。

相较于 YOLOv7 算法^[9],YOLOv9 中引入了程序化梯度信息 (programmatic gradient information system, PGI) 系统,通过辅助可逆分支确保深度网络中的信息传递和梯度流更加顺畅,减少信息丢失并优化模型训练。同时,广义高效层聚合网络 (general efficient layer aggregation network, GELAN) 结构通过高效的梯度路径规划,提高了参数利用率,降低了计算复杂性。多层级特征融合与反馈机制可以在各网络层次中有效整合和利用特征信息,提升网络的整体表现^[11]。

为提升全天候不同场景下的车辆类型信息提取的准确性与鲁棒性,解决实际场景中包含多种视角、光照、天气条件下不同尺寸和类型车辆识别困难的问题,在不同时间、天气下对快速路、主干道和次干道等进行车辆类型数据采集,建立数据集。实验中发现少量非机动车出现在机动车道上,参考《环境影响评价技术导则声环境》中车辆类型分类规则^[3],将车辆类型分为重型车、中型车、小型车和超小型车 (非机动车) 4 类^[3],采集共计 10 845 张各类型车辆的图片,并经过旋转、缩放和对比度调整等数据增强手段扩充至 21 690 张图片。数据集包含部分样本如图 2 所示。每张图片包含 2~15 辆车,其中重型车 44 290 辆,中型车 71 564 辆,小型车 102 156 辆,超小型车 19 048 辆,共计 237 058 辆车。

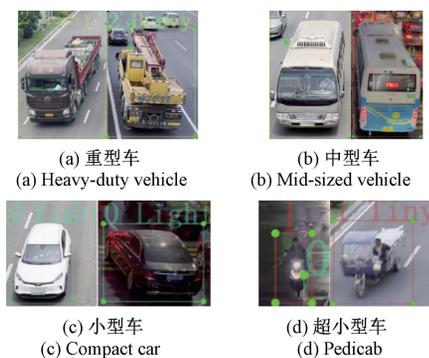


图 2 不同车辆类型

Fig. 2 Schematic of different vehicle types

通过手动标注 4 000 张典型场景数据,使用 YOLOv9 训练得到初步模型,将该模型用于自动标注剩下的 17 690 张图片;接着人工检查自动标注结果,进行校正,确保自动标注的准确性。合并手动标注和自动标注数据集,并按照 8:1:1 的比例划分为训练集、测试集和验证集,进一步训练和优化 YOLOv9 模型。输入视频数据进行检测,每帧视频中各个检测框即车辆类型检测结果图像,并将其作为车流量提取模型的输入视频图像。

1.2 基于 StrongSORT 多目标跟踪模型的车流量提取

视频监控中存在车辆遮挡、多车辆交叉以及车辆长时间停车等复杂情况,这使得准确提取车流量信息变得更为困难。针对这些问题,选用基于跟踪-检测框架的 StrongSORT (strong simple online and realtime tracker) 算法作为车流量提取的基础算法,该算法由 DeepSORT (deep simple online and realtime tracker) 算法改进而来,有着更好的追踪性能^[12]。

使用 YOLOv9 作为车辆类型检测器,整体跟踪流程图如图 3 所示。首先使用 YOLOv9 对监控视频中每一帧进行检测,得到每辆车辆的轮廓位置信息,将这些信息与图像输入 StrongSORT 算法中,利用提取到的外观信息与运动信息对轨迹和检测目标进行匹配,实现对多车辆的跟踪。

StrongSORT 通过采用指数移动平均 (exponential moving average, EMA) 抑制检测噪声,提高了同一车辆的匹配质量,且减少耗时;将 DeepSORT 中的普通卡尔曼滤波替换为自适应卡尔曼滤波,改善了低质量检测和噪声的敏感性,提高了更新阶段的准确性;DeepSORT 在第 1 次匹配时的代价矩阵中,使用外观特征进行匹配,运动特征仅用来除去不合理匹配。而 StrongSORT 中引入了外观和运动信息^[12]。其代价矩阵计算如式 (1) 所示。

$$\mathbf{M}_c = \lambda \mathbf{M}_a + (1 - \lambda) \mathbf{M}_m \quad (1)$$

其中, \mathbf{M}_a 是最小余弦距离矩阵,根据外观特征计算所得; \mathbf{M}_m 是马氏距离,根据运动信息计算所得; λ 是权重系数,本研究设为 0.98^[12]。相较于 DeepSORT 只使用外观特征,长时间停车的车辆容易出现匹配错误;同尺寸外观相近的车辆发生车辆遮挡、交叉时容易出现匹配错误,StrongSORT 在引入外观和运动信息后,能够在进行车辆匹配时参考车辆的前后位置变化,改善过度依赖外观信息而导致匹配错误的情况^[12]。

1.3 基于透视变换和帧间测速的车速提取

视频监控采集的信息丢失了三维空间中的深度信息,因而无法直接计算同一车辆在固定间隔帧内移动距离,进而计算车辆的速度^[13]。通过透视变化^[14],将视频图像中的二维点信息还原到对应点在真实三维坐标系中的坐标信息,可以有效保证物体真实位置信息的准确性,便于后续车辆测速。因每条道路的详细信息不同,对每条道路以车道线为参照进行 4 点标定,确定其真实世界中的位置关系,并将图像中的 4 个像素坐标点与真实三维坐标点建立对应关系,如式 (2) 所示。

$$\begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \begin{pmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \end{pmatrix} \cdot \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (2)$$

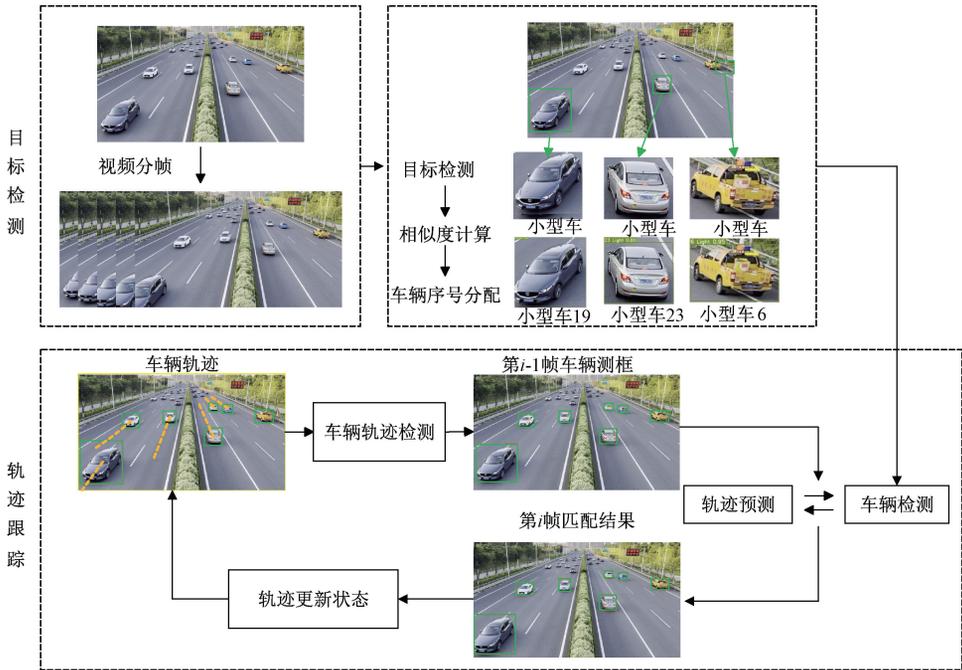


图 3 车辆追踪流程

Fig. 3 Flowchart of vehicle tracking

其中, $m_{11} \sim m_{33}$ 为变换系数, 透视变换后图像如图 4 所示。

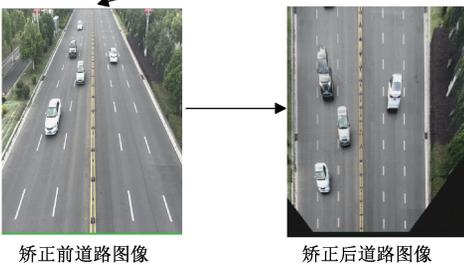


图 4 透视变换效果

Fig. 4 Perspective transformation illustration

视频图像经透视变化处理后, 采用帧间测速的方法, 记录每间隔 15 帧车辆中心的二维坐标点变换, 使用透视变换矩阵计算得到其真实世界中的位置, 进行车辆速度计算。实际测速效果如图 5 所示。

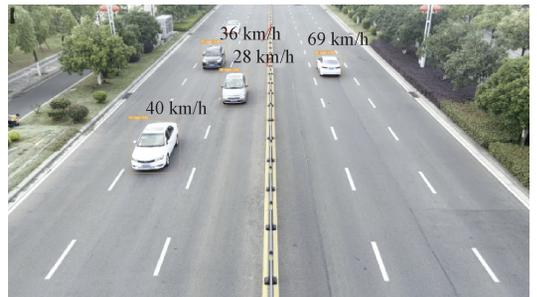


图 5 测速效果

Fig. 5 Speed measurement results

1.4 其他信息与噪声相关性分析与提取方法

除上述交通流信息外, 道路交通噪声与时间、风速、天气和路面存在相关性^[3]。在传统线性交通噪声估计模型中会考虑昼夜(时间)和路面类型作为模型修正量^[3]; 考虑到实验所在地实际道路交通场景中微风(0~3级)和小雨较为常见, 一并引入噪声相关变量中训练噪声估计模型。因现有研究尚未对大雨、大风和雪天等因素展开道路交通噪声相关性研究^[6], 同时受限于噪声采集设备工作条件, 故不考虑大雨、大风和雪天这 3 种天气。为了准确分析这些信息对城市道路交通噪声的影响, 将自动定位并从官方渠道匹配上述信息, 具体来源如表 1 所示。

表1 其他信息的格式与获取来源

Table 1 Format and sources of access to other information

数据类型	数据格式	数据来源
时间	YYYY-MM-DD HH:MM:SS	北斗卫星导航系统的授时服务
位置	经度、纬度	北斗卫星导航系统的定位服务
天气状况	晴/雨	中国气象局提供的实时天气数据
风速	风速等级	中国气象局提供的实时风向数据
路面	沥青/水泥	实地观察
噪声	每秒采集1次	AR844 噪声声级计

至此,所采集的数据包括交通流数据中车辆类型、车流量、车速,以及时间、位置、天气状况、风速、路面和噪声水平等。将交通流数据(每秒采集)转换为每 x 分钟内平均数据。时间信息按照白天(6:00~18:00)和夜晚(18:00~次日6:00)进行二进制编码,白天0、夜间1。天气信息中,天气状况编码为晴0、雨1。风速信息按照中国气象局风速等级标准进行编码,共18级风力等级。路面信息为沥青0、水泥1。上述数据处理工作便于后续噪声估计模型的训练与估计。

2 城市道路交通噪声实时估计模型

2.1 模型建立

噪声估计数据集中变量与噪声值存在复杂的非线性相关性;数据中包含少量干扰数据,如车辆鸣笛或路过行人高声喧哗等。常见的回归模型如线性回归^[6]、BPNN^[6]等,在非线性和泛化能力弱于SVR^[15]。因此选用SVR进行噪声估计。

为进一步增强噪声估计的准确性和泛化能力,采用改进的粒子群算法(improved particle swarm optimization, IPSO)对SVR的超参数 C 、 ϵ 和 γ 进行优化^[16]。流程图如图6所示。

通过对惯性权重和学习因子进行式(3)~(5)改进,将固定值改为了非线性变化值,避免粒子群算法(particle swarm optimization, PSO)会在高维空间或者复杂的非凸问题中陷入局部最优解。

$$\omega = \lambda \tan \left[\lambda \pi \left(1 - \frac{t}{m} \right) \right] \quad (3)$$

$$c_1 = c_{1\max} - (c_{1\max} - c_{1\min}) \left(\frac{t}{m} \right)^{0.2} \quad (4)$$

$$c_2 = c_{2\max} - (c_{2\max} - c_{2\min}) \left(\frac{t}{m} \right)^{0.2} \quad (5)$$

其中, λ 为非线性系数,本研究取0.45; t 为迭代次数; m 为最大迭代次数; $c_{1\max}$ 、 $c_{1\min}$ 、 $c_{2\max}$ 、 $c_{2\min}$ 分别为 c_1 和 c_2 的最值,本研究取2.0、0.8。通过上述改进,选取噪声估计数据

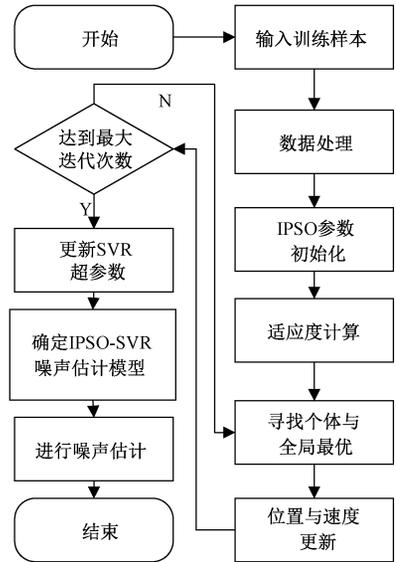


图6 IPSO-SVR噪声估计模型流程

Fig. 6 Flowchart of IPSO-SVR noise prediction model

集使用SVR训练,同时将SVR超参数作为粒子群的目标优化参数,粒子群规模设置为30,最大迭代次数设置为30,对比相同条件下PSO的适应度函数变化如图7所示。

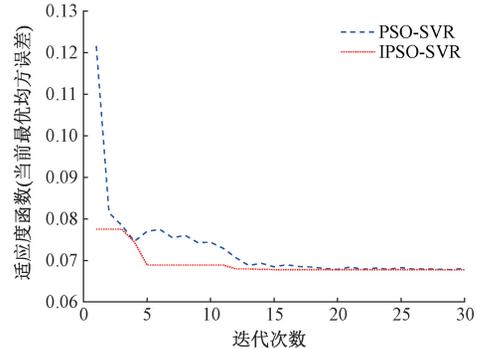


图7 城市道路交通噪声估计适应度变化曲线

Fig. 7 Urban road traffic noise prediction fitness variation curve

从图7中对比发现,相较于PSO适应度函数变化,IPSO的适应度曲线收敛速度提升明显,收敛效果更优。前期IPSO算法中惯性权重 ω 、个体学习因子 c_1 和群体学习因子 c_2 较大,更有利于全局搜索,而后期各项参数较小,很好的从全局搜索过渡到局部搜索;IPSO算法平衡了全局搜索和局部搜索能力,可以更快找到SVR参数的最优解,从而能够使城市道路交通噪声估计模型性能更优,估计结果更精准。

2.2 城市道路交通噪声实时估计流程

城市道路交通噪声实时估计模型的构建包含了数据采集与处理、交通流信息提取和城市道路交通噪声实时估计3个核心环节,如图8所示。

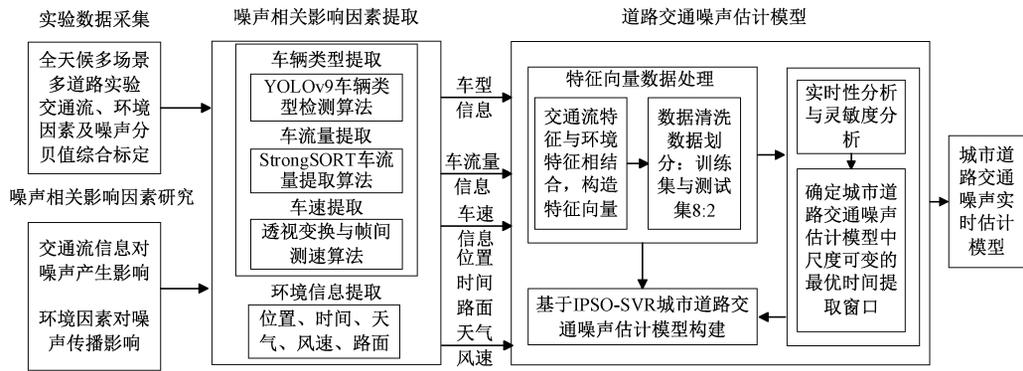


图 8 城市道路交通噪声实时估计流程

Fig. 8 Flowchart of urban road traffic noise real-time prediction

1) 通过实地采集噪声数值并采集监控设备视角下交通流视频,采用计算机视觉与深度学习算法提取噪声相关交通流信息,并自动根据位置信息从各官方渠道获取环境信息。

2) 基于上述提取的城市道路交通噪声相关信息,进行数据处理后,使用 IPSO-SVR 算法建立城市道路交通噪声估计模型。

3) 根据城市道路交通噪声估计模型,进行实时性与灵敏度分析,确定城市道路交通噪声估计中的时间尺度,并据此给出一整套实时性好,灵敏度高,抗干扰能力强的城市道路交通噪声估计方案,该部分研究在实验部分详细阐述。

3 实 验

3.1 数据集

依据《声环境质量标准》(GB 3096—2008)^[17]和《环

境噪声监测技术规范 城市声环境常规监测》(HJ 2.4—2021)^[18],选取典型城市道路,包含城市快速路、主干道和次干道,在不同的时间和天气下进行数据采集,如图 9 所示。根据城市道路噪声监测标准^[17],在地面高度 5 m 处架设相机,模拟实际监控设备视角进行录制;同步进行噪声采集,根据《声环境质量标准》(GB 3096—2008)^[17]和《环境噪声监测技术规范 城市声环境常规监测》(HJ 2.4—2021)标准^[18],在距离最外侧道路中心线 7.5 m 处,距离地面垂直高度 1.2 m 处的固定点位架设噪声采集设备 AR844 声级计(测量前进行校准)采集该路段的道路交通噪声,同时注意远离除地面外各类反射面 3.5 m。采集真实环境下道路交通的噪声分贝值,为后续噪声估计模型训练与噪声估计值对比提供数据支持。

实验共收集了 72 000 s 以上的视频数据,同步使用 AR844 声级计采集对应时间戳下每秒钟的噪声分贝值,建立城市道路交通噪声估计数据集。视频样本数据集中的采样地点、时间、天气、风速、噪声范围等部分数据如表 2 所示。

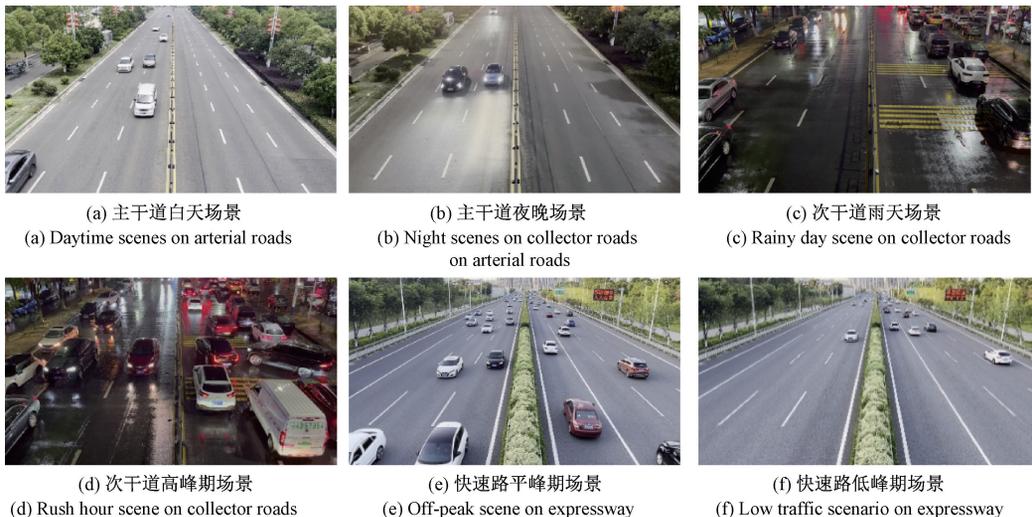


图 9 复杂环境下不同类型道路样本

Fig. 9 Sample maps of different road types in complex environments

表2 城市道路交通噪声估计数据集
Table 2 Urban road traffic noise prediction dataset

日期	地点	起始时间	结束时间	天气	风速/等级	噪声分贝值范围/dB
5月14日	赣江北大道	09:10	10:13	晴	2	[50.5,79.5]
5月14日	赣江北大道	11:02	12:36	晴	2	[49.2,79.9]
5月21日	赣江北大道	21:05	22:17	雨	2	[47.7,82.9]
6月27日	西一环路	11:30	12:30	晴	3	[62.5,81.5]
⋮	⋮	⋮	⋮	⋮	⋮	⋮
9月16日	西一环路	14:28	15:52	晴	1	[61.5,82.9]
9月16日	西一环路	17:30	18:30	晴	1	[61.1,81.8]
11月9日	京东大道	11:03	12:08	雨	2	[55.9,92.4]
11月9日	京东大道	16:00	17:13	雨	2	[56.9,87.4]
11月9日	京东大道	19:40	21:04	雨	2	[53.9,93.3]

3.2 实验环境

实验配备 CPU 为 12th Gen Intel (R) Core (TM) i5-12500H, GPU 为 NVIDIA GeForce RTX 2050, 操作系统为 Windows11-x64, 深度学习框架及函数依赖库为 Pytorch 1.12.1、CUDA 11.5。

3.3 评价指标

为验证车辆类型信息提取算法、车流量提取算法、车辆测速算法以及噪声估计模型的有效性, 采用表 3 所示评价指标进行验证。

3.4 实验结果分析

1) 交通流信息提取实验与结果

车辆类型提取算法的训练结果如图 10 所示, 各项指标在 150 次迭代后逐渐趋于稳定, 数据集的收敛速度较快, 说明了目标检测算法参数设置合理。图 10(a) 为训练的损失函数和准确率曲线, 损失函数最小值为 0.014 23, 准确率收敛于 97.38%; 图 10(b) 为召回率和平均精度均值曲线, 召回率收敛于 96.21%, 平均精度均值收敛于 98.33%。

表3 评价指标及描述说明

Table 3 Evaluation indicators and descriptive notes

模型名称	评价指标	描述说明
YOLOv9 车辆类型信息提取算法评价指标	平均精度均值 (mean average precision, mAP)	预测精度 ^[7] , 该值越高, 模型在判定为正例的样本中有更多的真正正例
	准确率 ($Precision$)	准确率 ^[7] , 数值越高, 模型预测效果越准确
	召回率 ($Recall$)	召回率 ^[7] , 数值越高, 模型对正例的覆盖更全面
YOLOv9+StrongSORT 车流量信息提取算法评价指标	身份切换总数 (identity switches, IDS)	身份切换总数 ^[19] , 数值越低, 发生 ID 切换次数越少, 多目标跟踪效果越好
	多目标跟踪准确度 (multi-object tracking accuracy, $MOTA$)	多目标跟踪准确度 ^[19] , 数值越高, 多目标跟踪任务中的性能越好
	多目标跟踪精度 (ID F1 score, $IDF1$)	多目标跟踪精度 ^[19] , 数值越高, 正确保持目标的标识符的能力越强
车速测速算法评价指标	均方根误差 (root mean square error, $RMSE$)	均方根误差 ^[20] , 反映测速值与实际值之间的平均偏差程度, 数值越小, 测速越准确
	平均误差精度 (mean percentage error, ϵ)	平均误差精度 ^[20] , 测速值与实际值的平均百分比误差, 数值越小, 预测精度越高
IPSO-SVR 噪声估计	均方误差 (mean square error, MSE)	均方误差 ^[20] , 对应时间尺度下噪声平均值 (声级计采集噪声实测值在对应时间尺度上的平均) 与噪声估计值之差平方后, 取其平均值。数值越小, 模型预测误差越小
	决定系数 (R-square, R^2)	决定系数 ^[20] , 越接近 1 拟合度越高, 表示噪声估计值与对应时间尺度下的噪声平均值越接近, 模型对目标变量的解释能力越强

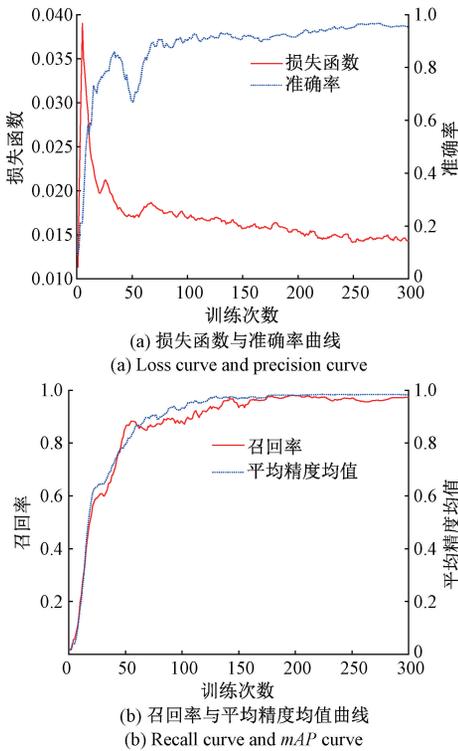


图 10 车辆类型提取算法结果分析

Fig. 10 Analysis of vehicle type extraction model results

在训练 YOLOv9 目标检测模型的同时,应用 HOG+SVM^[21]、YOLOv7^[9]、Faster-RCNN^[10] 等传统目标检测算法和深度学习目标检测算法在包含多种视角、光照、天气条件下不同尺寸和类型的车辆类型数据集上进行训练和测试,以便进行横向比较,各算法评价和分析结果如表 4 所示。

表 4 车辆类型提取算法结果对比分析

Table 4 Comparative analysis of vehicle type extraction model results

模型	Precision/%	Recall/%	mAP/%	预测时间/s
HOG+SVM	78.56	74.36	79.95	0.473
Faster-RCNN	95.13	95.32	96.14	0.159
YOLOv7	96.25	95.06	96.52	0.030
YOLOv8	95.78	95.43	95.81	0.027
YOLOv9	97.38	96.21	98.33	0.034

在车辆类型提取的目标检测任务中, YOLOv9 模型综合性能最优, 准确率为 97.38%, 召回率为 96.21%, mAP 值为 98.33%。该算法在不弱于其他算法的预测时间下, 能够准确的提取出不同视角下复杂场景中的车辆类型信息, 进而有效提高车流量提取算法的准确率。

车流量提取算法的实验结果如表 5 所示, 采用 YOLOv9+StrongSORT 的车流量提取算法的 3 项指标都最优, IDS 为 113, MOTA 为 91.3%, IDF1 为 87.7%, 因其较为复杂的网络结构, 使得预测时长略高于 DeepSORT。综合多指标考量, 该算法通过加入外观和运动信息, 能够有效改善车辆遮挡、多车辆交叉以及车辆长时间停车等导致匹配出错的情况, 性能兼顾了车流量提取的实时性和准确性。

表 5 车流量提取算法结果对比分析

Table 5 Comparative analysis of traffic flow extraction model Results

模型	IDS	MOTA/%	IDF1/%	预测时间/s
YOLOv9+DeepSORT	165	87.2	82.5	0.049
YOLOv9+StrongSORT	113	91.3	87.7	0.055

通过前期采集每条道路相邻车道线间距离, 结合车辆经过相邻两车道线的帧数后期计算出车速真实值, 帧间测速模型的实验结果如表 6 所示, 各个区间的测速值与真实值均值都非常接近, 均方根误差均 < 3 km/h, 平均误差精度均 < 3%, 说明通过透视变化能较为准确计算车辆速度。

表 6 不同速度区间车速测速算法结果

Table 6 Speed detection results for different intervals

速度区间/ (km·h ⁻¹)	真实值均 值/(km·h ⁻¹)	测速值均 值/(km·h ⁻¹)	均方根误 差/(km·h ⁻¹)	平均误差 精度/%
[0, 20]	7.72	7.73	0.23	2.44
(20, 40]	30.99	30.54	1.07	2.51
(40, 60]	52.32	52.73	1.42	2.32
(60, 80]	70.75	70.71	1.97	2.37
(80, 100]	84.79	84.25	2.58	2.71

2) 城市道路交通噪声实时性与灵敏度分析结果

传统噪声估计模型进行噪声估计时, 通常需要取 1 h 的平均值才能获得较好的结果。为了验证所提出的方法在不同时间尺度下噪声估计效果, 以确定满足城市道路交通噪声估计需求的时间尺度, 采用 MSE 与 R² 对城市道路交通噪声估计性能进行评估, 两评价指标具体公式如式(6)、(7)所示。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

其中, y_i 为对应时间尺度下噪声平均值(AR844 声级计采集噪声实测值在对应时间尺度上的平均); \hat{y}_i 为噪声估计值; \bar{y} 为所有样本实测噪声平均值。

从 0.5~20 min, 每间隔 30 s 取 1 次时间尺度, 将对应时间尺度下噪声平均值作为目标变量并将噪声相关变量作为特征变量进行城市道路交通噪声估计模型训练部分数据如表 7 所示。

表 7 不同时间尺度下部分噪声估计训练样本数据
Table 7 Noise estimation training sample data at different time scales

时间尺度/ min	小型车数量/ 辆	小型车平均车速/ (km·h ⁻¹)	超小型车数量/ 辆	超小型车平均车速/ (km·h ⁻¹)	重型车数量/ 辆	重型车平均车速/ (km·h ⁻¹)	中型车数量/ 辆	中型车平均车速/ (km·h ⁻¹)	天气	风速/ 等级	时间	路面类型	分贝平均值/dB
0.5	32	80.7	0	0	1	73.9	1	83.1	0	1	1	0	75.9
3	285	75.4	1	36.1	0	0	2	69.9	0	2	1	0	72.5
3	25	60.4	2	38.1	0	0	0	0	0	0	1	0	58.8
5	61	66.1	2	40.7	1	52.9	3	65.5	0	1	1	0	62.9
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
7	78	65.5	3	50.9	1	52.9	5	53.3	0	2	1	1	62.0
10	971	76.5	1	44.1	0	0	5	76.6	0	2	0	1	72.7
10	143	47.1	2	37.8	0	0	3	49.2	0	2	0	0	64.2
20	2 140	65.7	0	0	1	48.1	18	71.5	0	1	0	0	73.5

在表 7 中, 将基于计算机视觉提取的噪声相关交通流信息, 通过按照不同的时间尺度进行处理, 统计得到对应时间尺度下各类型车辆数量和平均车速以及其他相关信息, 运用于城市道路交通噪声估计模型训练, 训练结果如图 11 所示。

变强, 估计结果更为准确, 此时 R^2 为 0.991 6, MSE 为 0.230 9。随后时间尺度变大, 估计结果不会随时间尺度变化而剧烈变化。为进一步解释道路交通噪声估计准确性随时间尺度变化的动态规律, 截取一段时间内数据, 采用 3、5、10 min 为时间尺度, 对其进行噪声估计, 并与实测值曲线和噪声平均值曲线进行对比, 如图 12(a)~(c) 所示, 其中实测值曲线为 AR844 声级计采集原始数据, 平均值曲线以时间尺度作为滑动窗口将原始噪声数据计算局部的平均值, 估计值曲线为模型根据特征变量预测结果; 同步绘制噪声平均值与估计值散点图在不同误差带下的分布情况, 如图 12(d)~(f) 所示。

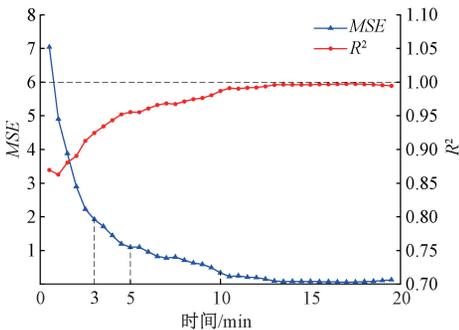


图 11 不同时间尺度估计结果对比

Fig. 11 Comparison of prediction results with different time scales

从图 11 可以发现, 随着时间尺度的增大, 其决定系数 R^2 逐渐增大, MSE 则在逐渐减小。当时间尺度为 3 min 时, MSE 开始较为平稳下降, 噪声与各变量之间的规律愈发明显, 当时间尺度为 10 min 时, 平均值滤波效果达到理想状态, 且交通流以及环境因素的规律性显著提高, 模型捕捉各变量与噪声分贝值之间关系的能力

如图 12(a)~(c) 所示, 当时间尺度为 3 min 时, 噪声平均值在 66~73 dB 之间波动, 估计值在平均值上下波动, 误差在 0~3 dB 之间, 具有较高的灵敏度与实时性; 当时间尺度变为 5 min 时, 噪声平均值在 67~72 dB 内波动, 趋势减弱, 估计值误差在 0~2.5 dB 之间; 当时间尺度为 10 min 时, 噪声平均值已趋于稳定, 平均值与估计值均在 69~71 dB 之间波动, 误差 < 1 dB。由此可见当时间尺度越大时, 平均值滤波效果更好, 其准确性增高但实时性和灵敏度较低。人耳对声音响度的可察觉差异可以设置为 1^[22] 和 3 dB^[23]。如图 12(d)~(f) 所示, 3 min 时间尺度下, 误差均在 3 dB 以内, 已难以被大部分人感知。当时间尺度增加至 5 min 时, 误差分布主要在 2 dB 误差带以内; 时间尺度为 10 min 时, 误差分布主要在 1 dB 误差带以内, 此时人耳无法感知 1 dB 以内的声

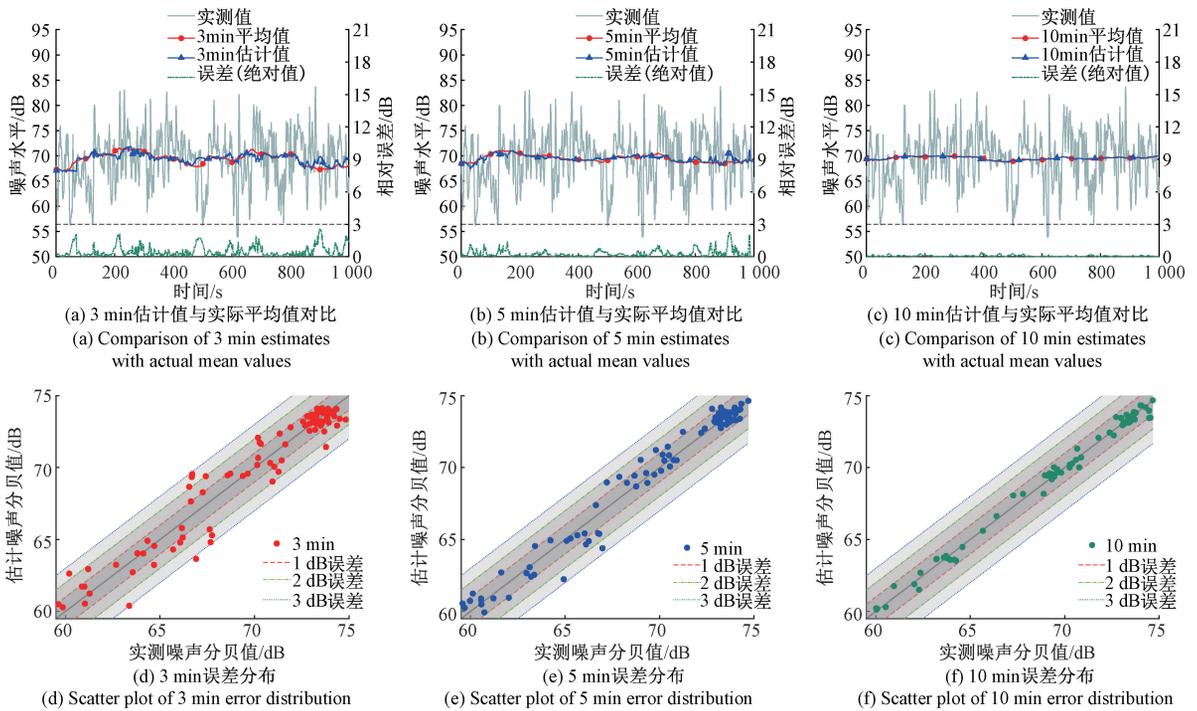


图 12 不同时间尺度估计结果与实际平均值对比

Fig. 12 Comparison of estimates and actual means at different time scales

压变化。因此在与其它算法对比时,时间尺度选取 3 和 10 min。

3) 不同方法的噪声估计结果分析

为验证所提城市道路交通噪声估计模型的准确性和鲁棒性,采用多元线性回归、BPNN 和 SVR 与 IPSO-SVR 进行不同场景下噪声估计结果对比分析。在多元线性回归中,按照标准^[3]中变量及各修正量取值要求进行计算;在构建 BP(back propagation)模型时,通过采取试错法多次实验验证确定设置 3 个隐藏层的 BP 模型,各隐藏层神经元分别为 64、32 和 16;在选取 SVR 参数时,根据网格搜索和五折交叉验证结果确定;同时使用与现有机器学习算法相同的自变量输入 IPSO-SVR 模型中,验证新加入变量对模型准确性影响。除多元线性回归以 1 h 和 10 min 为时间尺度外,其余算法均计算时间尺度为 3 和 10 min 的噪声估计结果指标。各模型的具体参数变量选择以及不同场景下结果对比如表 8 所示。

表 8 中方法 1 为多元线性回归算法,选取车辆类型、车流量、车速作为自变量,修正量为常数项。因不存在雨天修正量,无法估计雨天噪声;实验数据均为晴天采集,因此晴天估计结果与所有样本结果相同。当时间尺度为 1 h 时,所有样本的 $MSE = 9.347 0, R^2 = 0.671 5$,表明该方法进行噪声估计时对变量的解释能力较弱。其中,夜晚场景的结果偏差更为明显 $MSE = 10.975 0, R^2 = 0.615 1$;当时间尺度为 10 min 时,模型的解释能力进一

步下降,夜晚场景下的结果 $MSE = 12.896 2, R^2 = 0.547 7$ 。这说明多元线性回归模型无法解释变量与噪声之间存在的非线性关系。因此方法 1 不足以响应快速变化的城市道路交通噪声,不便于应用于时间尺度较小的噪声估计中。

方法 2 和 3 为机器学习算法,其中方法 2 采用 BPNN,方法 3 采用 SVR。方法 2 和 3 均选取车辆类型、车流量、车速和天气作为自变量,各算法的参数选取如表 8 中所示,各个场景的结果相较于方法 1,均有一定改善。时间尺度为 10 min 时,所有样本中,方法 2 的 $MSE = 1.273, R^2 = 0.951 5$;方法 3 的 $MSE = 2.247 5, R^2 = 0.920 8$,方法 2 总体的解释能力强于方法 3;但雨天场景下,方法 2 的 $MSE = 0.125 4, R^2 = 0.831 5$,方法 3 的 $MSE = 0.067 3, R^2 = 0.910 5$,说明雨天噪声样本受环境影响波动较大,BP 算法受异常值影响而过拟合,SVR 具有更好的泛化能力。时间尺度为 3 min 时,所有样本中,方法 2 的 $MSE = 2.319 0, R^2 = 0.897 2$;方法 3 的 $MSE = 4.356 6, R^2 = 0.793 1$,方法 2 和 3 的解释能力进一步下降。

方法 4 和本研究方法采用 IPSO-SVR 算法,区别在于变量选取不同,以验证增加时间、风速和路面 3 个变量对模型解释能力提升的有效性。时间尺度为 10 min 时,在所有样本中方法 4 的 $MSE = 0.336 8, R^2 = 0.988 1$,优于方法 1 ~ 3;在较为复杂的雨天环境中,方法 4 的

表8 不同方法应用于不同场景下的噪声估计结果

Table 8 Comparison of noise prediction results using different methods in various scenarios

估计方法	算法	变量选取	模型参数	场景	实验结果					
					时间尺度/min	MSE	R ²	时间尺度/min	MSE	R ²
方法1	多元线性回归 ^[3]	车辆类型、车流量、车速、修正量 ^[4]	$L_{eq}(T) = 10\log_{10} [10^{0.1L_{eq}(h)_{大}} + 10^{0.1L_{eq}(h)_{中}} + 10^{0.1L_{eq}(h)_{小}}]$	晴天	60	9.347 0	0.671 5	10	11.817 5	0.584 6
				雨天	60	-	-	10	-	-
				白天	60	7.256 3	0.747 9	10	10.742 9	0.623 2
				夜晚	60	10.975 0	0.615 1	10	12.896 2	0.547 7
				所有样本	60	9.347 0	0.671 5	10	11.817 5	0.584 6
方法2	BPNN ^[4]	车辆类型、车流量、车速、天气	$l=0.1, h=3$ $s=64 32 16$	晴天	10	2.588 6	0.925 6	3	2.147 1	0.933 2
				雨天	10	0.125 4	0.831 5	3	0.403 8	0.672 8
				白天	10	0.630 4	0.977 0	3	1.634 3	0.938 7
				夜晚	10	0.207 7	0.948 0	3	1.125 7	0.768 6
				所有样本	10	1.273	0.951 5	3	2.319 0	0.897 2
方法3	SVR ^[7]	车辆类型、车流量、车速、天气	10 min: $C=1, \varepsilon=0.01, \gamma=0.1$ 3 min: $C=100, \varepsilon=0.1, \gamma=0.01$	晴天	10	1.904	0.944 1	3	5.002 7	0.827 9
				雨天	10	0.067 3	0.910 5	3	0.284 1	0.766 4
				白天	10	1.785 2	0.934 3	3	5.443 2	0.802 3
				夜晚	10	0.202 3	0.940 1	3	0.982 9	0.747 4
				所有样本	10	2.247 5	0.920 8	3	4.356 6	0.793 1
方法4	IPSO-SVR	车辆类型、车流量、车速、天气	10 min: $C=130.74, \varepsilon=0.1402, \gamma=0.1873$ 3 min: $C=636.86, \varepsilon=0.6924, \gamma=0.0218$	晴天	10	0.520 0	0.984 7	3	1.966 1	0.938 8
				雨天	10	0.063 2	0.916 0	3	0.176 7	0.856 7
				白天	10	0.244 9	0.990 9	3	1.429 8	0.946 4
				夜晚	10	0.110 2	0.967 4	3	0.407 1	0.916 3
				所有样本	10	0.336 8	0.988 1	3	1.518 8	0.932 7
本文方法	IPSO-SVR	车辆类型、车流量、车速、天气、时间、风速、路面	10 min: $C=1000, \varepsilon=0.1681, \gamma=0.1303$ 3 min: $C=1000, \varepsilon=0.6357, \gamma=0.0100$	晴天	10	0.160 0	0.995 3	3	1.800 9	0.944 0
				雨天	10	0.053 8	0.928 5	3	0.168 6	0.867 4
				白天	10	0.240 1	0.991 0	3	1.323 6	0.950 4
				夜晚	10	0.091 0	0.973 1	3	0.398 1	0.918 1
				所有样本	10	0.230 9	0.991 6	3	1.429 6	0.936 6

$MSE = 0.063 2, R^2 = 0.916 0$, 高于方法2、3。时间尺度为3 min时,方法4在各个场景下同样优于方法2、3,所有样本 $MSE = 1.518 8, R^2 = 0.932 7$, 表明在使用IPSO对SVR的超参数寻优后,能够更好的解释变量与噪声之间的关系。相较于方法4,本文方法在添加时间、风速和路面3个变量之后,各个场景下模型性能优于方法4。在较为复杂的雨天场景,时间尺度为3 min时,本研究方法MSE减少4.5%, R^2 增加1.2%。这表明当模型增加变量后,IPSO-SVR能够更准确地捕捉和处理短时间变化的交通流信息、环境信息等与城市道路交通噪声的内在联系,使得估计准确性提升。从不同时间尺度的实验结果来看,10和3 min的噪声估计各有优势。10 min估计提供

了更为稳定和准确的噪声水平预测,但灵敏度较低,当有较高的准确性和稳定性需求时,可选取10 min作为城市道路交通噪声实时估计的时间尺度。3 min估计则能够更快地响应环境变化,适用于需要迅速评估和应对的情况。

实验分析表明,所提出基于计算机视觉的噪声相关交通流信息提取方法能够在不同视角、天气和光照下实现较常用的目标检测和目标追踪等计算机视觉算法更为准确的噪声相关交通流信息提取,其中,车辆类型识别准确率为97.38%,车流量提取跟踪准确率为91.3%,车速提取平均误差精度均小于3%。所建立的城市道路噪声估计模型较传统噪声估计模型有更高的实时性和准确性,较小时间尺度下估计结果更为准确;相较于现有基于

机器学习的噪声估计方法有着更为准确的估计结果,在不同场景下均有更高的准确性;当实时性要求较高时选取 3 min 为时间尺度,其所有样本的 $R^2 = 0.9366$;准确性要求较高时选取 10 min 为时间尺度,其所有样本的 $R^2 = 0.9916$ 。该方法能够准确估计城市道路交通噪声水平,为城市道路管理和规划、改善城市声环境质量提供依据,具有一定的实际应用价值。

4 结 论

针对噪声相关交通流信息采集不够便捷,成本高昂的问题,基于道路监控设备广泛普及的背景,提出了一整套自动化的城市道路交通噪声相关交通流信息采集方案,并给出了基于计算机视觉的城市道路交通噪声实时估计方法。该方法能够在不同视角、天气和光照下较为准确地提取交通流信息;结合 IPSO 算法对 SVR 超参数进行参数寻优,并在充分考虑车辆类型、车流量和车速等主要噪声相关变量后,加入非机动车、时间信息、天气信息、风速信息和路面信息等变量,使得噪声估计模型的准确性得到提升;确定了实时性要求较高时可选择时间尺度 3 min 进行噪声估计,准确性要求较高时可选择时间尺度 10 min 进行噪声估计,提供不同实时性和准确性的时间尺度选择,为城市噪声污染防治提供了同时兼备实时性与准确性的方案。

参考文献

- [1] MÜNDEL T, SØRENSEN M, DAIBER A. Transportation noise pollution and cardiovascular disease [J]. *Nature Reviews Cardiology*, 2021, 18(9): 619-636.
- [2] NOBILE F, FORASTIERE A, MICHELOZZI P, et al. Long-term exposure to air pollution and incidence of mental disorders. A large longitudinal cohort study of adults within an urban area [J]. *Environment International*, 2023, 181: 108302.
- [3] 孙滨, 陈亮, 王海波, 等. 考虑路网交通流状态的单变量交通噪声预测 [J]. *噪声与振动控制*, 2021, 41(2): 190-195.
SUN B, CHEN L, WANG H B, et al. Univariate traffic noise prediction considering road network traffic flow state [J]. *Noise and Vibration Control*, 2021, 41(2): 190-195.
- [4] LAN Z Q, CAI M. Dynamic traffic noise maps based on noise monitoring and traffic speed data [J]. *Transportation Research Part D: Transport and Environment*, 2021, 94: 102796.
- [5] BENOCCI R, MOLTENI A, CAMBIAGHI M, et al. Reliability of Dynamap traffic noise prediction [J]. *Applied Acoustics*, 2019, 156: 142-150.
- [6] CHEN L X, TANG B M, LIU T ZH, et al. Modeling traffic noise in a mountainous city using artificial neural networks and gradient correction [J]. *Transportation Research Part D: Transport and Environment*, 2020, 78: 102196.
- [7] ZHANG Y Y, ZHAO H M, LI Y, et al. Predicting highly dynamic traffic noise using rotating mobile monitoring and machine learning method [J]. *Environmental Research*, 2023, 229: 115896.
- [8] NOURANI V, GÖKÇEKUŞ H, UMAR I K. Artificial intelligence based ensemble model for prediction of vehicular traffic noise [J]. *Environmental Research*, 2020, 180: 108852.
- [9] 李响, 赖本涛, 张瑗霖, 等. 基于图像识别的铁路机车转向架螺栓紧固状态检测 [J]. *电子测量与仪器学报*, 2023, 37(12): 143-155.
LI X, LAI B T, ZHANG AI L, et al. Bogie bolt fastening state detection of railroad locomotives based on image recognition [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(12): 143-155.
- [10] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测 [J]. *仪器仪表学报*, 2021, 42(12): 167-174.
CHEN R X, ZHAN Z, HU X L, et al. Printed circuit board defect detection based on the multi-attentive faster RCNN under noise interference [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(12): 167-174.
- [11] WANG C Y, YEH I H, LIAO H Y M. YOLOv9: Learning what you want to learn using programmable gradient information [J]. *ArXiv preprint arXiv: 2402.13616*, 2024.
- [12] DU Y H, ZHAO ZH CH, SONG Y, et al. StrongSORT: Make DeepSORT great again [J]. *IEEE Transactions on Multimedia*, 2023, 25: 8725-8737.
- [13] YEONG D J, VELASCO-HERNANDEZ G, BARRY J, et al. Sensor and sensor fusion technology in autonomous vehicles: A review [J]. *Sensors*, 2021, 21(6): 2140.
- [14] 刘钰嵩, 何丽, 袁亮, 等. 动态场景下基于光流的语义 RGBD-SLAM 算法 [J]. *仪器仪表学报*, 2022, 43(12): 139-148.
LIU Y S, HE L, YUAN L, et al. Semantic RGBD-SLAM in dynamic scene based on optical flow [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(12): 139-148.
- [15] BI J X, ZHAO M Q, YAO G B, et al. PSOSVRPos: WiFi indoor positioning using SVR optimized by PSO [J]. *Expert Systems with Applications*, 2023, 222: 119778.

- [16] CHOUDHARY P, KUMARI K, SHARMA D, et al. Surface nanoarchitectonics of boron nitride nanosheets for highly efficient and sustainable ipso-hydroxylation of arylboronic acids[J]. ACS Applied Materials & Interfaces, 2023, 15(7): 9412-9420.
- [17] 中华人民共和国环境保护部, 国家质量监督检验检疫总局. 声环境质量标准: GB 3096—2008[S]. 北京: 中国环境科学出版社, 2008.
Ministry of Environmental Protection of the People's Republic of China, General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China. Environmental quality standard for noise: GB 3096—2008[S]. Beijing: China Environmental Science Press, 2008.
- [18] 中华人民共和国生态环境部, 环境影响评价技术导则声环境: HJ 2.4—2021[S]. 北京: 中国环境科学出版社, 2021.
Ministry of Ecology and Environment of the People's Republic of China. Technical guidelines for noise impact assessment: HJ 2.4—2021[S]. Beijing: China Environmental Science Press, 2021.
- [19] YANG H, CHANG F L, HUANG Y H, et al. Multi-object tracking using Deep SORT and modified CenterNet in cotton seedling counting[J]. Computers and Electronics in Agriculture, 2022, 202: 107339.
- [20] 李强龙, 孙建瑞, 赵坤, 等. 基于IALO-SVR的锂电池健康状态预测[J]. 电子测量与仪器学报, 2022, 36(1): 204-211.
LI Q L, SUN J R, ZHAO K, et al. Lithium battery health status prediction based on IALO-SVR[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 204-211.
- [21] ZHOU H ZH, YU G. Research on pedestrian detection technology based on the SVM classifier trained by HOG and LTP features[J]. Future Generation Computer Systems, 2021, 125: 604-615.
- [22] VIGEANT M C, CELMER R D, JASINSKI C M, et al. The effects of different test methods on the just noticeable difference of clarity index for music[J]. The Journal of the Acoustical Society of America, 2015, 138(1): 476-491.

- [23] 李响, 李国正, 邓明君, 等. 基于语音频谱图像特征的人体疲劳检测方法[J]. 仪器仪表学报, 2021, 42(2): 123-132.
LI X, LI G ZH, DENG M J, et al. A human fatigue detection method based on speech spectrogram features[J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 123-132.

作者简介



李响, 2004年于重庆大学获得学士学位, 分别在2007年和2016年于北京交通大学获得硕士和博士学位, 现为华东交通大学硕士生导师, 江西开放大学副教授, 主要研究方向为安全技术及工程、信号处理和机器视觉。

E-mail: leexx82@163.com

Li Xiang received his B. Sc. degree from Chongqing University in 2004, received his M. Sc. degree and Ph. D. degree both from Beijing Jiaotong University in 2007 and 2016, respectively. Now he is a lecturer at East China Jiaotong University. His main research interests include safety engineering, signal processing and artificial intelligence.



张璠霖(通信作者), 2022年于华东交通大学获得学士学位, 现为华东交通大学硕士生研究生, 主要研究方向为机器视觉与图像处理。

E-mail: zal2000@qq.com

Zhang Ailin (Corresponding author) received his B. Sc. degree from East China Jiaotong University in 2022. He is currently a master student at East China Jiaotong University. His main research interests include machine vision and image processing.



李国正, 分别在2005年和2014年于北京交通大学先后获得学士和博士学位, 现为北京交通大学副教授, 主要研究方向为信号检测和模式识别。

E-mail: liguozheng@bjtu.edu.cn

Li Guozheng received his B. Sc. degree and Ph. D. degree both from Beijing Jiaotong University in 2005 and 2014, respectively. He is currently an associate professor at Beijing Jiaotong University. His main research interests include signaldetection and pattern recognition.