

面向数字道路的典型交通设施表观智能检测与识别研究综述

付迪¹ 王金¹ 许牛琦¹ 李浩¹ 翟鸿漾¹
FUDi WANG Jin XU Niuqi LI Hao ZHAI Hongyang

摘要

随着交通强国的快速建设,交通基础设施表观智能检测与识别是数字道路底座的重要支撑。通过车道线、非机动车道路标线、交通标志和护栏这四个常见的交通基础设施,分别从经典机器学习方法和深度学习网络入手,归纳分析了各类算法在道路设施检测和识别中的优缺点。相较于经典机器学习下的表观检测和识别方法,深度学习网络更能兼顾准确性和鲁棒性,在复杂环境下,如遮挡、磨损、光线变化等实际场景中展现出一定的泛化性能。最后,总结展望了交通基础设施检测和识别中仍然面临的挑战。

关键词

数字道路;道路设施识别;机器学习;深度学习

doi: 10.3969/j.issn.1672-9528.2024.11.048

0 引言

截至2023年底,中国公路总里程已达543.68万公里^[1],正逐渐从“交通大国”迈向“交通强国”,交通数字化也同步迈入快速发展通道。数字道路作为智慧交通的重要基石,是智能交通管理、自动驾驶和智慧城市建设等多个领域的基石^[2]。基于激光雷达、摄像头等设备采集道路交通设施的表观信息,利用机器学习方法,获取了精准、高效的交通设施三维信息,成为道路设施数字化的底座。

车道线、非机动车道路标线、交通标志和护栏是道路交通基础设施的重要组成要素。道路标线通常以文字、线条、立面标记等形式铺设在路面上,以实现划分车道线、指示驾驶员交通信息和引导车流等功能,一般以颜色、形状和线条等作为其描述特征^[3]。其中铺设在路面上以线条的形式来指示车道宽度和行车方向的称为车道线,其他道路标记可称为非机动车^[4]道路标线。交通标志有着指引行车信息、调节交通量等作用,准确识别和理解交通标志对于安全、高效地行驶至关重要^[5-6]。对护栏的检测可以用于确定车辆最大可行驶区间,并且能够在一定程度上反映前方道路结构的变化^[7]。因此,本文从车道线、非机动车道路标线、交通标志和护栏这四个典型要素出发,分类梳理交通设施感知与检测模型,并进行了归纳总结。

各种设备采集的检测感知数据可归纳为图像和点云数据。图像一般是车载摄像机获得的RGB(红绿蓝)等信息

生成的^[8],包含了目标对象丰富的视觉信息,如颜色、纹理等特征,但受光照、遮挡等因素的影响较大。利用激光雷达等传感器采集的点云数据,记录了道路场景的三维空间坐标和灰度值等信息,数据受光照等影响较小,但由于点云数据的无序等特性,计算复杂度和对硬件性能要求相对较高。

融合图像和点云数据进行多模态特征融合也逐渐被学者所关注。点云可以提供精准的几何信息,图像能够保留丰富的视觉信息,因此,Feng等人^[9]开创性地提出了利用MatchNet学习二维和三维描述符间的距离来配准图像和点云数据。在此基础上,诸如基于视觉惯性里程计(visual-inertial odometry)^[10]、交替方向乘子法(alternating direction method of multipliers)^[11]、空间变压器网络(spatial transformer network)^[12]等配准方法不断涌现,进一步促进了图像点云融合技术的发展。

公共数据集被广泛用于评价所提出模型的性能。在表1中列出了在交通基础设施领域的常见数据集,其中对于图像数据集,大小为其图片张数;对于点云数据集,大小为其点个数,单位为M(兆)、TB(万亿)。总的来说,受硬件成本等影响,目前用于交通基础设施检测的图像数据集比点云数据集更为常见。

表1 常见交通基础设施领域数据集

数据集	模态	适用目标	大小
TuSimple ^[13]	图像	非机动车道路标线 / 车道线	6408
CULane Datasets ^[14]	图像	非机动车道路标线 / 车道线	133 235
Toronto-3D ^[15]	点云	非机动车道路标线	78.3 M

1. 北京工业大学城市交通学院 北京 100124

[基金项目] 北京市自然科学基金项目(8232005);北京市自然科学基金-丰台轨道交通前沿研究联合基金(L221026);国家自然科学基金(41801380)

表 1(续)

数据集	模态	适用目标	大小
BDD100K ^[16]	图像	非机动车道路标线 / 车道线	1.2×10 ⁸
MASTIF ^[17]	图像	交通标志	10 000
CCTSD ^[18]	图像	交通标志	17 856
GTSRB ^[19]	图像	交通标志	50 000
STSD ^[20]	图像	交通标志	3777
DFG ^[21]	图像	交通标志	6957
Unsupervised Llamas ^[22]	图像	车道线	100 042
Apollp Scape ^[23]	图像	车道线	143 906
A2D2 ^[24]	点云	车道线	2.3 TB
KITTI ^[25]	图像 / 点云	车道线 / 护栏	14 999/—

1 车道检测研究现状与分析

现有的车道检测方法可以分为基于经典机器学习的方法和基于深度学习网络的方法。经典的车道线检测方法主要来自图像处理技术，通过人为设计的特征提取和识别阈值实现车道线的提取和跟踪^[26]。随着计算机计算能力的提升，研究者开始探索基于深度学习的车道线检测方法，此类方法在实验中表现出较好的鲁棒性。

1.1 基于经典机器学习的车道线检测方法

传统的车道线检测方法，首先对图像进行去噪、增强等预处理操作，获取感兴趣区域，然后使用预定义特征来提取车道线的特征信息，最后拟合特征信息提取车道线。总而言之，面向行车道线检测的经典机器学习算法可以分为基于特征识别的方法和基于数学建模的方法。

1.1.1 基于特征识别的车道线检测

特征识别常利用边缘检测、Hough 变换等方法来放大车道线与背景之间的颜色变化、梯度差异等信息，进而将车道线从背景中分离开来。Zhou 等人^[27]提取车道线的梯度特征，实现车道线检测。但是由于梯度特征对光线敏感，阴暗或强光照条件会影响检测结果。为此，Low 等人^[28]选择 Canny 边缘检测和霍夫变换来减少光照等变化对检测结果的影响，在特征提取的基础上利用霍夫变换检测直线，再根据距离参数和方位角参数对车道线进行建模。为了应对复杂场景，2024 年，荣红佳^[29]提出了一种基于 Sobel 算子和 HSV 颜色空间模型，并结合霍夫变换的三模型车道线检测方法，弥补了单一方法的不足，大幅提升了车道线检测的准确性和鲁棒性。这类方法计算效率高，实时性好，在比较理想的道路环境下可以较为准确地实现车道线检测的功能，但在实际环境中容易受到噪声等的影响。

1.1.2 基于数学建模方法

考虑到基于特征识别的方法在复杂环境下容易受干扰的缺点，一些学者提出了基于数学建模的车道线检测方法，在分析车道线结构特征的基础上，通过数学建模的方式拟合出符合当前环境的线性曲线。2004 年，Wang 等人^[30]设计了 B-Snake 模型，通过将车道边界检测问题转化为利用透视平行线来检测车道中线的问题，该方法对环境中的噪声、阴影和光照变化均表现出较好的鲁棒性，但对于弯曲车道检测精度并不高。2015 年，何鹏等人^[31]提出了一种结合 Hough 变换和 Catmull-Rom 插值曲线算法的弯曲车道检测方法，通过霍夫变换得到近端车道线位置和曲线控制点，再通过这些控制点来拟合远端车道线。2022 年，Yan 等人^[32]针对以往研究主要集中在 2D 车道线检测，忽略车道线在三维空间的几何特性的问题，提出了一种基于先验知识和几何约束的单目图像的 3D 车道线检测方法，利用道路平面假设和消失点信息构建 3D 车道线估计算法，从而有效恢复车道线的三维空间信息。

相较于基于特征识别的车道线检测方法，基于数学建模的方法更加复杂，在检测准确性和鲁棒性方面表现更佳。但这类方法依赖于阈值参数不仅会增加人工成本，还会受到经验的限制，导致可能出现偏差；此外考虑到车道线线性特征的多样性，仅依靠简单曲线模型无法满足车道线检测的要求。

1.2 基于深度学习网络的车道线检测方法

近年来，深度学习网络通过自学、迭代优化的方式，极大地提高了检测的自动化程度。现有的深度学习算法按照模型构建的不同，可以分为基于语义分割的方法和基于目标检测的方法。根据数据来源，可划分为基于图像的方法和基于图像、点云融合的方法。本文根据数据来源不同，归纳总结车道线检测网络。

1.2.1 基于图像深度学习网络的车道线检测方法

得益于图像数据集的易获得性和神经网络的权值共享、自动学习等特点，基于图像的深度学习车道检测技术得到了广泛的应用。基于卷积神经网络（convolutional neural network，CNN）架构，学者们提出了多种深度学习模型。这些方法通过端到端的学习，直接从图像中预测车道线的位置和形状。自 2014 年 Kim 等人^[33]开创性地将一个 8 层的 CNN 卷积网络与随机样本一致性算法（random sample consensus algorithm，RANSAC）相结合进行车道的检测，随后诸如 DeepLane^[34]、SegNet^[35]、YOLOv3^[36]等模型也纷纷被应用于车道检测中，并取得了较好效果。

尽管融合 CNN 能够显著提高车道检测精度，但传统 CNN 架构在处理长距离空间依赖关系和捕捉全局上下文信息方面存在局限性，为此研究者们引入注意力机制来自适应地

提高模型对车道线关键区域的关注度,来进一步提高模型的鲁棒性。2022年,在引入通道注意力模块和自注意力模块的基础上,Yao等人^[37]设计了一种轻量级的车道检测网络。通过融合不同层级的特征信息,在兼顾速度的同时提高模型的检测精度,在CULane数据集上达到了95.11%的精度。2023年,在LaneNet架构上,万海波等人^[38]提出了一种针对摩托车车道的实时检测方法,使用K-means算法代替Mean-Shift聚类算法,并且去除H-Net结构,有效提高了算法的检测精度。针对基于卷积神经网络的车道检测方法存在的效率不佳问题,2024年,葛泽坤等人^[39]提出了多头注意力机制下的轻量级车道检测方法,通过融合移动瓶颈卷积模块与特征压缩模块,降低模型的参数,建立兼顾检测精度和推理速度的全局注意力网络。

1.2.2 融合图像和点云融合的车道线检测方法

由于点云的稀疏性和无序性,在数据处理和特征提取上效率往往受限。目前,融合图像和点云的多模态方法逐渐成为学者们进行车道线检测的重要方法。

2017年,Qi等人^[40]提出具有开创性意义的点云深度学习模型PointNet,融合点云的深度学习方法逐渐在车道线检测任务中受到关注。随后Qi等人^[41]率先将图像和点云数据进行融合,提出Frustum PointNets框架来进行3D目标检测,并在KITTI数据集上取得了当时的最佳结果。2021年,Zhang等人^[42]设计了一种通道注意力模块,进行图像和点云数据的跨通道信息融合,较大幅度地提升了车道线检测精度。为了更好地融合图像和点云数据,2023年,金祖亮^[43]提出了在鸟瞰图(birds eye view,BEV)空间融合图像和点云,开展多传感器数据的特征级车道线检测方法,其结合激光雷达数据来优化BEV特征图的生成,并采用动态注意力结构来实现不同传感器通道的特征融合。针对多模态目标检测框架中存在的二维特征图分辨率不足导致的边界模糊问题,Xu等人^[44]则提出了一种多模态融合框架,在语义分割的基础上采用校准参数将二维语义信息重新投影到三维点云中,并引入自适应注意力的融合模块来进一步融合2D-3D信息。融合图像的丰富纹理信息和点云的三维几何信息进行车道线检测,在一定程度上弥补了单一传感器的局限性,但是由于数据维度的不同,在实际应用中仍存在数据融合算法复杂、数据偏差等局限。

现有的深度学习算法,无论是采用图像数据还是将图像、点云数据融合,都需要大量的标注数据。前者需要将图像中的每个像素都标记为是否属于车道,这种方法依赖于车道的分割图作为监督,但车道长而窄的特点使得标注后的车道像素远低于背景像素,给模型的学习带来挑战。后者虽然避免了稀疏的车道线像素标注问题,但也同样面对数据标注要求高的问题。

为了减轻深度学习对标注的依赖问题,多任务学习(multi-task learning)^[45]、消息传递(message passing)^[46]等方法被应用到深度学习模型中,Lee等人^[47]针对恶劣天气下车道线检测问题,将消失点作为多个视觉感知任务的共享知识点来指导模型训练。Pan等人^[48]则在其车道检测模型中融入空间MP,帮助信息在神经元中的传递。Hou等人^[49]开发了一种不需要额外标签和外部监督的自注意力蒸馏模型,通过利用从自身各层提取的注意力图作为下层的蒸馏目标来强化对车道特征的学习。尽管如此,现有的车道检测模型仍然面临泛化能力不足的问题,可能导致在特定场景下训练的模型在其他场景下性能不佳。

1.3 本章小结

传统的基于特征识别的方法和基于数学建模的方法,算法相对简单,能够满足一定的实时性要求,但是准确性和鲁棒性有待提升;基于深度学习的车道线检测方法,在检测准确性方面已经达到较高水平,但还存在两个主要待解决的问题。

(1) 数据标注缺乏及泛化能力不足。为了减少模型对数据标注依赖,文献[49]和文献[50]分别提出了自我蒸馏和深度对比学习方法,旨在通过让模型从无标注或弱标注的数据中学习,从而提高其泛化能力和效率。同时迁移学习、数据增强等工作也能进一步提高模型的性能。

(2) 难以部署到移动设备上。CNN复杂而有效的性能需要以数百万的参数作为支撑,通过设计更为高效的轻量级神经网络来提高模型的计算效率,此外也可以尝试将经典的计算机视觉方法与深度学习相结合,开发出融合二者优势的车道线检测方法。

2 非车道道路标线识别研究现状与分析

相较于车道线检测,检测和识别非车道道路标线的研究相对较少,但在城市道路交叉口等组织复杂的交通流场景下,非车道道路标线往往能为驾驶员提供更为详细的视觉引导信息,因此,对非车道道路标线的精准检测和识别也是支撑数字道路的关键环节之一。现行的经典机器学习和深度学习的方法,虽在特定标线识别上精度较高,但由于数据集相对较少,无法全面适应复杂多变的现实环境,一定程度上约束了模型的泛化性能^[51],图1为非车道道路标线示例。



(a) 指示车辆行驶方向



(b) 道路限速 60~80 km

图1 非车道道路标线示例

2.1 基于经典机器学习的非机动车道交通标线识别方法

早期对道路标线的采集一般是通过摄像机进行的,因此大多数的非机动车道路标线研究都是基于图像数据,即通过区分标线与普通路面在同一环境下颜色和图案的不同来提取标线。一般由去噪、特征提取和分类三部分构成,常采用边缘检测、颜色分割、模型匹配、Hough变换和RANSAC等方法^[52]。

2008年,Aly等人^[53]开发了一种基于城市俯视图的道路标线检测方法,采用高斯滤波对图像进行过滤,在此基础上采用RANSAC算法拟合出平滑的贝塞尔样条曲线来表示道路标线,但是该方法需要预知道道路标线的大致位置才能有效地跟踪和识别。随后,Chira等人^[54]提出了一种基于模板匹配的道路标线检测识别方法,在对图像进行反向透视基础上,将标记好的模板与图像进行匹配,实现了城市道路环境下的实时监测,但识别精度有待提高。2012年,Suchitra等人^[55]将图像分为若干个区域,并对每个区域分别进行边缘检测,然后利用Hough变换分析其梯度值和峰值,并结合角度倾斜分析实现最终的检测。该方法有效提高了道路标线的检测识别精度,但对图像完整性的较高要求限制了其整体鲁棒性。2013年,Qin等人^[56]综合Hu不变矩、边缘点数等特征提出了一种借助支持向量机(support vector machine, SVM)的道路标线检测方法,较大幅度提高了标线的检测精度。

基于点云的检测方法也在逐渐发展。2013年,Yang等人^[57]提出了一种基于扫描角度的路面点云分割方法,利用动态中值滤波器对标线的边缘点进行检测,但检测精度有待提高。2021年,Mi等人^[58]设计了一种从移动激光扫描点云中自动提取和建模的两级目标检测和定位道路标记方法,该方法对反射强度、不同点密度和局部遮挡的变化具有一定的鲁棒性。

2.2 基于深度学习的非机动车道交通标线识别方法

考虑到经典机器学习方法难以处理复杂的非线性关系和高维数据,能够自动学习数据特征并进行端到端处理的深度学习网络得到更多青睐。

2.2.1 图像深度学习网络下的非机动车道交通标线识别

2015年,Chan等人^[59]提出了一种基于级联主成分分析(principal component analysis, PCA)、二进制哈希和块直方图的无监督深度学习卷积网络PCANet,并在多个图像数据集进行测验。在此基础上,Chen等人^[60]在进行道路标线识别时采用二值化赋范梯度方法进行目标检测,利用PCANet进行对象分类,在实验数据集上取得了96.8%的准确度。随后,针对较差光线和阴影遮挡条件下道路标线提取困难的问题,Bailo等人^[61]提出了一种结合PCANet和SVM的深度学习网络来对道路标线进行分类。在YOLOv4的基础上,赵明声^[62]将U-Net作为分割网络来对道路标线破损问题

进行研究,引入深度可分离卷积来降低参数量,并结合注意力机制和K-means++算法来进一步提高检测的准确度。

2.2.2 点云深度学习网络下的非机动车道交通标线识别

此外,结合点云数据进行基于深度学习模型的道路标线检测的研究也获得了一定的进展。2019年,Wen等人^[63]提出一种结合U-Net语义分割模型和多尺度聚类的深度学习框架,用于从MLS点云中道路标线实现识别和分类。为了降低道路标线的破损和缺失对标线提取过程的影响,2023年,孙刚豪^[64]提出了一种基于低线束车载激光雷达的路面标线病害检测与性能评估的方法,通过region of interest algorithm (ROI)算法提取标线所在区域,结合最大类间方差算法自动分割格式化标线,再利用种子区域生长算法实现道路标线病害的提取和分类。

2.3 本章小结

尽管现行的非机动车道路标线检测方法能够达到较高精度,但是基于预定义特征的检测和分类限制了其泛化能力。且目前大多数算法采用基于全局阈值的分割方法,可能会引入大量噪声,从而降低提取道路标线的效率。此外由于道路磨损和障碍物遮挡导致的道路标线提取不完整,也会影响检测识别结果的准确性。

未来非机动车道路标线检测识别技术的发展可以从多源数据融合、数据集鲁棒性、高精地图信息叠加等方面入手。标注完整、内容丰富的数据集可以为深度学习提供更为充足的训练样本,结合高精地图提供的先验知识,如道路几何结构、标线位置等,进一步提高检测的准确性和可靠性,同时提高算法对标线语义信息的理解能力。

3 交通标志检测研究现状与分析

经典机器学习方法通常是对交通标志的形状、颜色等特性进行提取,然后将这些特征输入到分类器中,进而实现对交通标志的检测和分类。随着深度学习的发展,其强大的特征提取能力和表征能力使其能够显著提高交通标志检测精度和自动化程度,成为目前主流的研究方向。

3.1 基于经典机器学习的交通标志检测方法

经典机器学习方法可以分为三类:基于颜色、形状和基于多属性的方法,在2010年前,研究人员倾向于采用基于颜色和基于形状的方法,因为这种方法相对简单,但精度较低,难以处理复杂的交通标志。随着技术的发展,融合颜色、形状和纹理等多属性信息的交通标志检测方法得到了更广泛的应用。

3.1.1 基于颜色、形状特征的交通标志检测方法

作为经典的交通标志提取方法,1997年,Escalera等人^[65]通过设置RGB阈值和最佳角探测器来提取标志的颜色

和几何特征。2010年,在颜色距离变换和前向特征选择技术的基础上,Ruta等人^[66]通过构建离散RGB图最大值和最小值阈值进而得到高度区分的符号描述符,提高了交通标志的检测进度。但由于RGB信息易受光线影响,人为设定的阈值受场景约束较大。针对该问题,Vitabile等人^[67]引入HSV动态阈值分类识别交通标志,有效提高了检测精度和鲁棒性,但处理时间较长,仍然无法满足复杂环境条件下的交通标志检测的需要。

3.1.2 基于多属性特征的交通标志检测方法

随着对交通标志的进一步了解,基于多属性的方法在2015年之后更为常见。在对交通标志的颜色、形状、纹理等信息进行特征提取的基础上,使用自适应增强(Adaptive Boosting, AdaBoost)或SVM等分类器对融合后的特征进行处理,得到交通标志的分类识别结果。这类方法充分地吸纳了不同属性的优点,使其性能优于基于单一属性的方法。

2014年,Liu等人^[68]利用分流级联的树状结构来构建基于多类交通标志共同特征的交通标志特征检测器,结合AdaBoost算法查找不同训练集的共同特征,实现高效快速的多类交通标志检测。该方法适用于训练样本较充足的情况,当训练样本较少时,学者们则更倾向于利用SVM来挖掘交通标志的多属性特征。2016年,Hu等人^[69]设计了一个包含密集特征提取器和检测器的单阶段学习通用框架,并引入了空间池化作为聚合通道特征的一部分来增强特征对噪声和图像变形的鲁棒性。同年,Berkaya等人^[70]使用圆圈算法和RGB颜色阈值进行交通标志检测识别,融合了定向梯度直方图、局部二元模式和Gabor特征的SVM分类器,该方法在准确性和实时性方面实现了较好的平衡。尽管基于多属性的方法能够相对准确地实现交通标志的识别检测,但受限于对阈值参数或特征的高度依赖性,仍难以很好地泛化到复杂多变的应用场景中。

3.2 基于深度学习网络的交通标志检测方法

CNN作为最早应用成功的深度学习模型,在目标检测与分类上具有较好的鲁棒性,在交通标志检测领域得到了广泛应用。2014年,Girshick等人^[71]在CNN中引入候选区域特征提取模块,将目标检测分为候选区域生成、区域分类与回归两个步骤,并以此提出了著名的两阶段目标检测算法——R-CNN,进一步提高了检测边界框的定位精度。随后,在R-CNN基础上,Ren等人^[72]提出了能较大提高检测速度的Faster R-CNN,采用神经网络来生成检测框,并与检测网络共享卷积特征,成为R-CNN系列最优秀的算法。为了进一步节约计算资源和提高检测速度,Redmon等人^[73]于2016年提出了单阶段目标检测的YOLO模型,采用端到端的方

式将目标检测问题转换为单一的回归问题,直接在图像上显示检测对象的类别概率和坐标,大大提高了检测的实时性。但相比于R-CNN系列算法,其精度有所降低。同年,在YOLO算法的基础上,Liu等人^[74]结合Faster R-CNN的锚框思想提出了SSD算法,通过采用多尺度先验框来选定不同大小的目标,使其在保留较高检测速度的同时提高精度,但对小目标的检测能力较弱。针对该问题,2017年,Lin等人^[75]提出了特征金字塔网络,结合Faster R-CNN网络得到了融合深层特征和浅层特征的高分辨率语义信息,提高了对较小交通标志的检测识别能力。

此后对交通标志检测算法的改进多是在现有的网络上进行。2021年,针对SSD对小目标交通标志检测精度不佳的问题,田智慧等人^[76]在原SSD特征图基础上,加入底层特征图,并将邻近底层特征图进行融合,采用K-means聚类分析调整检测框大小,使其在提高检测精度的同时满足实时性的要求。2023年,简林源^[77]构建了一种面向自然场景的交通标志识别算法,在DCV-YOLOX模型的基础上融合Dense感受野和注意力机制来提高网络的特征提取能力,并采用Varifocal Loss损失函数来进一步加快模型的收敛,极大地提高了模型在恶劣天气下的识别准确性和鲁棒性。同年,熊恩杰等人^[78]提出了一种面向交通标志的Ghost-YOLOv8检测算法,使用GhostConv代替部分Conv,减少了模型的参数量,并在Neck部分添加GAM注意力机制模块,强化了特征中的语义信息和位置信息。

3.3 本章小结

相较于经典的交通标志检测算法,深度学习网络在准确性和鲁棒性上有着更加优异的表现,但同时也还存在一些局限。

(1)就数据集而言,基于深度学习的方法依赖于大量经过标注后的数据集,目前大多数采用公共数据集进行训练,在准确度和实时性上都达到了较高水平,但这也意味着在此类数据集上不同方法的性能提升空间不大,需要包含遮挡、模糊、恶劣环境等特点的图像样本,以增强模型的泛化能力。此外,现有的模型在训练时通常只使用某一特定数据集,可以考虑采用跨数据集迁移学习、主动学习等方法来提高模型在新场景下的泛化能力。

(2)就算法而言,作为道路环境下的小目标,交通标志的视觉范围通常较窄,使得模型难以提取足够丰富的特征信息,还需要进一步开发对小目标具有较强鲁棒性的算法。同时考虑到交通标志检测的实时性要求,需要在模型精度和推理速度之间寻求平衡。下一步可以探索轻量级网络结构或知识蒸馏技术,保证检测精度的同时提高模型的运行效率。

同时,利用时序信息和上下文语义,如结合目标跟踪或场景理解技术,可以进一步提升检测的稳定性和准确性。

4 护栏检测研究现状与分析

相较于其他交通基础设施如道路标志标线,针对护栏检测的相关研究较少。根据检测算法的不同,可以将其分为基于经典机器学习和基于深度学习网络的方法;依据检测数据的来源可以分为三类:基于图像、基于点云、融合图像和点云的方法。下面依据检测方法对护栏检测的相关研究进行综述。

4.1 基于经典机器学习的护栏检测方法

传统的检测多基于经典的机器学习技术,利用边缘检测、聚类等人设计的特征提取方法,再结合传统的分类器如 SVM 等进行分类。2007 年, Alessandretti 等人^[79]设计了一种融合图像和点云数据的护栏检测方法,对图像预处理后,运用水平 Sobel 算子过滤掉垂直方向的分量,搜索出护栏可能存在的区域,再结合点云数据进行准确定位。虽然该方法仅适用于速度低于 5km/h 的行车环境下,但为护栏检测迈出了重要一步。随后, Seibert 等人^[80]结合 Local Binary Patterns 和 Lucas-Kanade 算法,通过跟踪 Harris 特征来对二维图像上的护栏进行检测,但该方法只能检测出是否有护栏,无法确定护栏的位置。针对该问题,2014 年, Scharwachter 等人^[81]依据单目摄像机拍摄的图像,采用 Sobel 滤波器检测边缘及其方向,通过 Hough 变换进行护栏定位,但是这种方法仅适用于白天。为了更加精确地识别护栏,李振宇等人^[82]选择利用双目视觉道路巡检设备采集的护栏数据,结合改进的边缘提取和线性拟合分析算法,提出一种基于双目视觉的护栏形变自动检测及高速里程定位方法。

就基于点云数据的研究而言,2016 年, Jiang 等人^[83]使用不连续检测等方法估计出护栏几何特征点,然后通过跟踪护栏的长度和宽度轨迹来细化护栏特征点,以此将护栏分离出来。郭斌则通过分析护栏的结构特点,构建护栏的点云特征,并提出冗余特征点滤除算法来解决噪声干扰问题,随后利用二次曲线模型对护栏进行描述,从而建立了高速公路护栏检测方法。针对高速公路波纹梁护栏检测实时性差、准确率低的问题,2021 年,贺普铮^[84]提出并实现了一种基于实例分割的波纹梁护栏快速检测算法。该算法采用多尺度自适应特征融合算法和高斯弱化机制的极值矩阵迭代筛选算法,解决了信息丢失和筛选候选框的过度抑制问题。

4.2 基于深度学习网络的护栏检测方法

利用深度学习网络的护栏检测研究,起步相对较晚。考虑到护栏的几何结构,现阶段多采用基于图像的分割和目

标检测网络来实现。2020 年, Kasuga 等人^[85]提出了一种基于车载摄像头的护栏外观检测方法,将全卷积网络和防锈检测相结合,实现护栏外观质量检测与分类。2021 年, Yi 等人^[86]开发了一个基于 Xception 神经网络架构的迭代主动学习 AI 工具来检测农村道路的路侧护栏。2022 年,金豪^[87]引入单阶段 Yolact 实例分割模型,并基于 ResNet101 骨干网络的多尺度自适应特征融合结构,实现对高速公路波形纹护栏的实时检测。同年,吴俊^[88]则引入 YOLOv4-Tiny 目标检测算法,提取护栏图像 ROI,在此基础上,提出改进 DeeplabV3+ 模型,实现护栏图像的语义分割,利用相机-激光雷达联合标定实现图像和点云的数据融合,进一步实现护栏梁板、护栏立柱和路面的点云分割。2024 年,王洋等人^[89]在利用 MobileNetv2 网络替换 DeepLabV3+ 主干网络的基础上,引入空间分组增强注意力机制来检测护栏,提出了一种改进 DeepLabV3+ 的无人机高速公路护栏检测方法。

深度学习模型,能够自动学习特征并实现端到端的检测的特点。深度学习的护栏检测方法相较于传统方法,大幅提升了对不同形状、材质护栏的适应性和鲁棒性,在复杂环境下表现出更出色的性能。但由于深度学习模型依赖于大量标注处理后的数据集,数据收集和标注过程繁琐耗时,且目前并没有公开的大规模道路护栏专用数据集;此外护栏形状和材质的复杂性也给特征提取带来了挑战,一定程度上限制了深度学习网络的拓展应用。

4.3 本章小结

虽然目前对护栏的检测识别依据取得了一定的进展,但在精确性、鲁棒性及成本上还存在着一定的局限性。

就检测方法而言,以摄像机作为传感器来处理图像数据容易受到光照等条件的干扰,对于摄像机的架设位置也有一定的要求,同时采集的图像只包含了线形外观等特征,忽略了护栏的深度信息;借助激光雷达来收集数据不受时间和光照条件的限制,可以量化出护栏的破损情况,但点云数据量大、算力需求大,也很难满足实时性的要求。

就检测结果而言,目前的研究结果大多只能检测直线路段,对于弯道路段的检测效果仍显不足;此外,目前还没有形成统一的护栏检测评价标准,大多数研究只涉及某一类护栏的性能评估,使得各种护栏检测算法之间缺少可比性。

5 结语

随着计算机科学和人工智能的发展,数字道路是推动智慧城市建设和交通运输创新发展的基石。目前面向数字道路的交通基础设施检测的相关研究得到了广泛关注,取得了飞跃性进展。本文根据现有文献,从车道检测、非机动车道标线、

交通标志和护栏四个方面对交通基础设施感知检测技术进行了归纳总结。现有技术在检测识别准确性、实时性上都达到了较好的水平,但仍有一些问题需要进一步解决。

(1) 相较于图像深度学习网络的广泛应用,点云深度学习网络相对较少,而其中的一个重要因素受制于点云数据的稀疏性和无序性,常见深度学习网络架构较为复杂,往往效率不高。未来,搭建更为轻量化的网络架构是实时、高精度提取识别道路设施的关键。

(2) 融合图像点云的环境感知技术也是目前的重要研究方向。该技术通过多源数据的优势互补,助力实现对复杂道路环境的全面感知。但此类方法模型结构复杂,数据对齐和校准困难,实时性有待提高,在实际应用中还面临着多模态数据的一体化建模、不同层级架构融合等问题。

(3) 面向不同类别道路场景的基础设施高精度分类网络。由于不同等级道路设施在空间分布和几何形态等方面有较大差异,目前的多阶段检测融合策略,易产生误差累积的问题。未来期待建立高精度、轻量化的端到端一体化模型。

参考文献:

- [1] 2022 年交通运输行业发展统计公报 [N]. 中国交通报, 2024-06-18.
- [2] 王建伟, 高超, 董是, 等. 道路基础设施数字化研究进展与展望 [J]. 中国公路学报, 2020,33(11): 101-124.
- [3] 刘伟. 基于深度神经网络的道路标识标线识别系统研究 [D]. 重庆: 重庆交通大学, 2022.
- [4] GUPTA A, CHOUDHARY A. A framework for camera-based real-time lane and road surface marking detection and recognition[J]. IEEE transactions on intelligent vehicles, 2018,3(4): 476-485.
- [5] OHN-BAR E, TRIVEDI M M. Looking at Humans in the Age of Self-Driving and Highly Automated Vehicles[J]. IEEE transactions on intelligent vehicles, 2016,1(1): 90-104.
- [6] ZHU Z, LIANG D, ZHANG S H, et al. Traffic-sign detection and classification in the wild[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 2110-2118.
- [7] 郭斌. 基于激光雷达的高速公路护栏检测方法研究 [D]. 重庆: 重庆邮电大学, 2019.
- [8] 梁振明, 黄影平, 宋卓恒, 等. 自动驾驶中基于深度学习的 3D 目标检测方法综述 [J]. 上海理工大学学报, 2024,46(2): 103-119.
- [9] FENG M D, HU S X, ANG M H, et al. 2d3d-matchnet: Learning to match keypoints across 2d image and 3d point cloud[C]//2019 International Conference on Robotics and Automation (ICRA). Piscataway:IEEE, 2019: 4790-4796.
- [10] YU H, ZHEN W K, YANG W, et al. Monocular camera localization in prior lidar maps with 2D-3D line correspondences[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway: IEEE, 2020: 4588-4594.
- [11] 赵阳. 基于深度学习的图像-点云跨模态配准方法 [D]. 济南: 山东师范大学, 2023.
- [12] LAI B Q, LIU W Q, WANG C, et al. Learning cross-domain descriptors for 2D-3D matching with hard triplet loss and spatial transformer network[C]//International Conference on Image and Graphics. Cham: Springer, 2021:15-27.
- [13] TuSimple. Tusimple Benchmark[EB/OL] (2022-10-12) [2024-03-21]. <https://github.com/TuSimple/tusimple-benchmark>.
- [14] PAN X G, SHI J P, LUO P, et al. Spatial as deep: Spatial cnn for traffic scene understanding[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto:AAAI Press, 2018:7276-7283.
- [15] TAN W K, QIN N N, MA L F, et al. Toronto-3D: A large-scale mobile LiDAR dataset for semantic segmentation of urban roadways[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2020: 797-806.
- [16] YU F, XIAN W Q, CHEN Y Y, et al. BDD100K: a diverse driving video database with scalable annotation tooling[BD/OL]. (2020-04-08)[2024-03-15].<https://doi.org/10.48550/arXiv.1805.04687>.
- [17] ŠEGVIĆ S, BRKIĆ K, KALAFATIĆ Z, et al. Exploiting temporal and spatial constraints in traffic sign detection from a moving vehicle[J]. Machine vision and applications, 2014,25(3): 649-665.
- [18] ZHANG J M, ZOU X, KUANG L D, et al. CCTSDB 2021: a more comprehensive traffic sign detection benchmark[J]. Human-centric Computing and Information Sciences, 2022,12:23.
- [19] STALLKAMP J, SCHLIPSING M, SALMEN J, et al. The German traffic sign recognition benchmark: a multi-class classification competition[C]//The 2011 International Joint Conference on Neural Networks. Piscataway:IEEE, 2011: 1453-1460.
- [20] LARSSON F, FELSBURG M. Using Fourier descriptors and

- spatial models for traffic sign recognition[C]//Image Analysis. Berlin: Springer-Verlag Berlin Heidelberg, 2011: 238-249.
- [21] TABERNIK D, SKOČAJ D. Deep learning for large-scale traffic-sign detection and recognition[J]. IEEE transactions on intelligent transportation systems, 2019,21(4): 1427-1440.
- [22] BEHRENDT K, SOUSSAN R. Unsupervised labeled lane markers using maps[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops. Piscataway: IEEE, 2019: 832-839.
- [23] HUANG X Y, CHENG X J, GENG Q C, et al. The apollo-cape dataset for autonomous driving[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway:IEEE, 2018: 954-960.
- [24] GEYER J, KASSAHUN Y, MAHMUDI M, et al. A2d2: Audi autonomous driving dataset[DB/OL]. (2020-04-14) [2024-04-26].<https://doi.org/10.48550/arXiv.2004.06320>.
- [25] GEIGER A, LENZ P, STILLER C, et al. Vision meets robotics: The kitti dataset[J]. The international journal of robotics research, 2013,32(11): 1231-1237.
- [26] CHETAN N B, GONG J Y, ZHOU H Y, et al. An overview of recent progress of lane detection for autonomous driving[C]//2019 6th International Conference on Dependable Systems and Their Applications (DSA). Piscataway:IEEE, 2020: 341-346.
- [27] ZHOU S Y, JIANG Y H, XI J Q, et al. A novel lane detection based on geometrical model and gabor filter[C]//2010 IEEE Intelligent Vehicles Symposium. Piscataway:IEEE,2010: 59-64.
- [28] LOW C Y, ZAMZURI H, MAZLAN S A. Simple robust road lane detection algorithm[C]//2014 5th International Conference on Intelligent and Advanced Systems (ICIAS). Piscataway:IEEE, 2014: 1-4.
- [29] 荣红佳. 基于滑动窗搜索算法在车道线检测方面的改进[J]. 时代汽车, 2024(7): 175-177.
- [30] WANG Y, TEOH E, SHEN D G. Lane detection and tracking using B-Snake[J]. Image and vision computing, 2004,22(4): 269-280.
- [31] 何鹏, 高峰, 魏厚敏. 基于 Catmull-Rom 样条曲线的弯曲车道线检测研究[J]. 汽车工程学报, 2015,5(4): 276-281.
- [32] YAN F, NIE M, CAI X Y, et al. Once-3DLanes: Building monocular 3d lane detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE, 2022:17143-17152.
- [33] KIM J H, LEE M H. Robust lane detection based on convolutional neural network and random sample consensus[C]// Neural Information Processing, Part I. Berlin:Springer, 2014: 454-461.
- [34] GURGHIAN A, KODURI T, BAILUR S V, et al. Deeplanes: End-to-end lane position estimation using deep neural networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2016: 38-45.
- [35] BADRINARAYANAN V J, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE transactions on pattern analysis and machine intelligence, 2017,39(12): 2481-2495.
- [36] REDMON J, FARHADI A. YOLOv3: an Incremental Improvement[DB/OL].(2018-04-08)[2024-04-28]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [37] YAO Z T, CHEN X Y, GUINDEL C. Efficient lane detection technique based on lightweight attention deep neural network[J]. Journal of advanced transportation, 2022(3): 1-13.
- [38] 万海波, 蒋磊, 王晓. 基于深度学习的摩托车车道实时检测[J]. 计算机科学, 2023,50(S01): 450-454.
- [39] 葛泽坤, 陶发展, 付主木, 等. 改进多头注意力机制的车道检测方法[J]. 计算机工程与应用, 2024,60(2): 264-271.
- [40] QI C R, SU H, MO K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE, 2017: 652-660.
- [41] QI C R, LIU W, WU C X, et al. Frustum pointnets for 3d object detection from rgb-d data[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 918-927.
- [42] ZHANG X Y, LI Z W, GAO X, et al. Channel attention in LiDAR-camera fusion for lane line segmentation[J]. Pattern recognition, 2021,118: 108020.
- [43] 金祖亮. 基于多传感器融合的自动驾驶 3D 目标检测和车道线分割研究[D]. 重庆: 重庆交通大学, 2023.
- [44] XU S Q, LI F, SONG Z Y, et al. Multi-sem fusion: multi-modal semantic fusion for 3D object detection[J]. IEEE transactions on geoscience and remote sensing, 2024,62:53-69.
- [45] CARUANA R. Multitask learning: a knowledge-based source of inductive bias[C]//International Conference on Machine Learning. New York: JMLR.org, 1993: 41-48.
- [46] BATTAGLIA P, PASCANU R, LAI M, et al. Interaction net-

- works for learning about objects, relations and physics[C]//Advances in Neural Information Processing Systems 29,vol. 7, 2016:4509-4517.
- [47] LEE S K, KIM J S, YOON J S, et al. Vpgnet: Vanishing point guided network for lane and road marking detection and recognition[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway:IEEE, 2017: 1947-1955.
- [48] PAN X G, SHI J D, LUO P, et al. Spatial as deep: Spatial CNN for traffic scene understanding[C]//Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence, Volume Nine. Palo Alto: AAAI Press, 2018:6665-7655.
- [49] HOU Y N, MA Z, LIU C X, et al. Learning lightweight lane detection cnns by self attention distillation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway:IEEE, 2019: 1013-1021.
- [50] XIAO Z W, XING H L, ZHAO B W, et al. Deep contrastive representation learning with self-distillation[J]. IEEE transactions on emerging topics in computational intelligence, 2024,8(1):3-15.
- [51] LIM K Y, HONG Y W, KI M S, et al. Vision-based recognition of road regulation for intelligent vehicle[C]//2018 IEEE Intelligent Vehicles Symposium (IV). Piscataway:IEEE, 2018: 1418-1425.
- [52] YING Z Q, LI G. Robust lane marking detection using boundary-based inverse perspective mapping[C]//2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway:IEEE, 2016: 1921-1925.
- [53] ALY M. Real time detection of lane markers in urban streets[C]//2008 IEEE Intelligent Vehicles Symposium. Piscataway: IEEE, 2008: 165-170.
- [54] CHIRA I M, CHIBULCUTAN A, DANESCU R G. Real-time detection of road markings for driving assistance applications[C]//International Conference on Computer Engineering & Systems, 2010:158-163.
- [55] SUCHITRA S, SATZODA R K, SRIKANTHAN T. Detection & classification of arrow markings on roads using signed edge signatures[C]//2012 IEEE Intelligent Vehicles Symposium,[v.2].Piscataway: IEEE, 2012:796-801.
- [56] QIN B, LIU W, SHEN X, et al. A general framework for road marking detection and analysis[C]//16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013). Piscataway:IEEE, 2013: 619-625.
- [57] YANG B S, WEI Z, LI Q H, et al. Semiautomated building facade footprint extraction from mobile lidar point clouds[J]. IEEE geoscience and remote sensing letters, 2013,10(4): 766-770.
- [58] MI X X, YANG B S, DONG Z, et al. A two-stage approach for road marking extraction and modeling using MLS point clouds[J]. ISPRS Journal of photogrammetry and remote sensing, 2021,180: 255-268.
- [59] CHAN T H, JIA K, GAO S H, et al. PCANet: a simple deep learning baseline for image classification?[J]. IEEE trans image process, 2015,24(12): 5017-5032.
- [60] CHEN T R, CHEN Z L, SHI Q, et al. Road marking detection and classification using machine learning algorithms[C]//2015 IEEE Intelligent Vehicles Symposium (IV). Piscataway:IEEE, 2015: 617-621.
- [61] BAILO O, LEE S, RAMEAU F, et al. Robust road marking detection and recognition using density-based grouping and machine learning techniques[C]//2017 IEEE Winter Conference on Applications of Computer Vision (WACV). Piscataway: IEEE, 2017: 760-768.
- [62] 赵明升. 基于深度学习的道路标线破损检测研究 [D]. 西安: 西安工业大学, 2023.
- [63] WEN C L, SUN X T, LI J T, et al. A deep learning framework for road marking extraction, classification and completion from mobile laser scanning point clouds[J]. ISPRS journal of photogrammetry and remote sensing, 2019,147: 178-192.
- [64] 孙刚豪. 基于低线束车载激光雷达的路面标线病害检测与性能评估 [D]. 长春: 吉林大学, 2023.
- [65] De La ESCALERA A, MORENO L E, SALICHS M A, et al. Road traffic sign detection and classification[J]. IEEE transactions on industrial electronics, 1997,44(6): 848-859.
- [66] RUTA A, LI Y M, LIU X H. Real-time traffic sign recognition from video by class-specific discriminative features[J]. Pattern recognition, 2010,43(1): 416-430.
- [67] VITABILE S, POLLACCIA G, PILATO G, et al. Road signs recognition using a dynamic pixel aggregation technique in the HSV color space[C]//Proceedings 11th International Conference on Image Analysis and Processing. Piscataway:IEEE, 2001: 572-577.
- [68] LIU C S, CHANG F L, CHEN Z X. Rapid Multiclass Traffic Sign Detection in High-Resolution Images[J]. IEEE transactions on intelligent transportation systems, 2014,15(6): 2394-

- 2403.
- [69] HU Q C, PAISITKRIANGKRAI S H, SHEN C, et al. Fast Detection of Multiple Objects in Traffic Scenes With a Common Detection Framework[J]. IEEE transactions on intelligent transportation systems, 2016,17(4): 1002-1014.
- [70] BERKAYA S K, GUNDUZ H, OZSEN O, et al. On circular traffic sign detection and recognition[J]. Expert systems with applications, 2016,48: 67-75.
- [71] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE, 2014: 580-587.
- [72] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2017,39(6): 1137-1149.
- [73] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE, 2016: 779-788.
- [74] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//Computer Vision—ECCV 2016. Cham: Springer, 2016: 21-37.
- [75] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 2117-2125.
- [76] 田智慧, 孙盐盐, 魏海涛. 基于 SSD 模型的交通标志检测算法 [J]. 计算机应用与软件, 2021,38(12): 201-206.
- [77] 简林源. 自然场景下的交通标志识别算法研究 [D]. 南昌: 南昌大学, 2023.
- [78] 熊恩杰, 张荣芬, 刘宇红, 等. 面向交通标志的 Ghost-YOLOv8 检测算法 [J]. 计算机工程与应用, 2023,59(20): 200-207.
- [79] ALESSANDRETTI G, BROGGI A, CERRI P. Vehicle and guard rail detection using radar and vision data fusion[J]. IEEE transactions on intelligent transportation systems, 2007,8: 95-105.
- [80] SEIBERT A, HÄHNEL M, TEWES A, et al. Camera based detection and classification of soft shoulders, curbs and guardrails[C]//2013 IEEE Intelligent Vehicles Symposium (IV). Piscataway:IEEE, 2013: 853-858.
- [81] SCHARWÄCHTER T, SCHULER M, FRANKE U. Visual guard rail detection for advanced highway assistance systems[C]//2014 IEEE Intelligent Vehicles Symposium Proceedings. Piscataway:IEEE, 2014: 900-905.
- [82] 李振宇, 李林, 朱晓峰, 等. 基于双目视觉的形变护栏检测及里程定位 [J]. 交通科技与经济, 2022,24(2): 24-33+63.
- [83] JIANG Y, HE B, LIU L, et al. Effective and robust corrugated beam guardrail detection based on mobile laser scanning data[C]//2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). Piscataway:IEEE, 2016: 1540-1545.
- [84] 贺普峰. 复杂背景下高速公路护栏及裂缝检测系统设计与实现 [D]. 哈尔滨: 哈尔滨工业大学, 2021.
- [85] KASUGA K, HAKAKAWA R, IWAHASHI M. Classification of In-Vehicle Camera Images for Guardrail Inspection Support[C]//2020 IEEE 2nd Global Conference on Life Sciences and Technologies (LifeTech). Piscataway:IEEE, 2020: 113-114.
- [86] YI H, BIZON C, BORLAND D, et al. Ai tool with active learning for detection of rural roadside safety features[C]// 2021 IEEE International Conference on Big Data (Big Data). Piscataway:IEEE, 2021: 5317-5326.
- [87] 金豪. 基于深度学习的公路护栏目标检测方法研究 [D]. 重庆: 重庆交通大学, 2022.
- [88] 吴俊. 基于图像点云融合的公路波形梁护栏使用状态评价 [D]. 北京: 北京交通大学, 2022.
- [89] 王洋, 郭杜杜, 王庆庆, 等. 基于改进 DeepLabV3+ 的无人机高速公路护栏检测 [J]. 激光与光电子学进展, 2024, 61(4): 240-248.

【作者简介】

付迪(2001—), 女, 湖北荆州人, 硕士, 研究方向: 车辆碰撞安全预警。

王金(1984—), 通信作者(email: j.wang@bjut.edu.cn), 女, 河南南阳人, 博士, 副教授, 研究方向: 时空大数据下道路设施数字化与智能养护分析。

(收稿日期: 2024-07-29)