

控制与决策

Control and Decision

半结构化场景下移动机器人视觉边线检测综述

苏晓杰, 刘星雨, 李睿, 谭威, 郜深阵

引用本文:

苏晓杰, 刘星雨, 李睿, 谭威, 郜深阵. 半结构化场景下移动机器人视觉边线检测综述[J]. *控制与决策*, 2023, 38(6): 1491–1509.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1678>

您可能感兴趣的其他文章

Articles you may be interested in

[基于机器视觉的喷涂机器人轨迹规划与涂装质量检测研究综述](#)

Trajectory planning for spray-painting robot and quality detection of paint film based on machine vision: A review

控制与决策. 2023, 38(1): 1–21 <https://doi.org/10.13195/j.kzyjc.2022.1438>

[基于视频的人体异常行为识别与检测方法综述](#)

Overview of video based human abnormal behavior recognition and detection methods

控制与决策. 2022, 37(1): 14–27 <https://doi.org/10.13195/j.kzyjc.2020.1428>

[基于深度强化学习的机器人运动控制研究进展](#)

Research progress of robot motion control based on deep reinforcement learning

控制与决策. 2022, 37(2): 278–292 <https://doi.org/10.13195/j.kzyjc.2020.1382>

[移动机器人运动规划中的深度强化学习方法](#)

Deep reinforcement learning for motion planning of mobile robots

控制与决策. 2021, 36(6): 1281–1292 <https://doi.org/10.13195/j.kzyjc.2020.0470>

[面向复杂网络的异常检测研究进展](#)

Research progress of anomaly detection for complex networks

控制与决策. 2021, 36(6): 1293–1310 <https://doi.org/10.13195/j.kzyjc.2020.0055>

半结构化场景下移动机器人视觉边线检测综述

苏晓杰[†], 刘星雨, 李睿, 谭威, 郜深阵

(重庆大学自动化学院, 重庆 400044)

摘要: 面向机器人自主运动的视觉感知技术是实现机器人与环境交互的关键技术之一, 边线作为保证机器人运动安全的一种视觉信息, 具有广泛的研究价值, 而半结构化场景为边线检测带来新的挑战. 基于手工提取特征的检测方法在面对非城市环境或路面视觉信息不明显的复杂场景时并不能表现出鲁棒性, 利用深度学习方法进行边线检测已成为一种主流趋势. 鉴于此, 针对半结构化场景下的移动机器人视觉边线检测研究进行综述, 考察部分边线检测算法在半结构化场景下的应用前景与应用效果. 首先, 对常用的边线检测数据集进行整理, 从采集场景、标注类型等角度分析当前数据集及研究的侧重点; 其次, 对不同的方法进行分类与总结, 比较检测与数据处理过程; 接着, 对深度学习常用的评价指标进行整理, 并对不同方法在面对不同场景时的检测效果进行比较和分析; 最后, 针对半结构化场景下边线检测所存在的问题, 对基于深度学习的视觉边线检测方法的研究方向进行展望.

关键词: 视觉感知; 边线检测; 半结构化场景; 深度学习; 数据集; 评价指标

中图分类号: TP391.4

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1678

引用格式: 苏晓杰, 刘星雨, 李睿, 等. 半结构化场景下移动机器人视觉边线检测综述[J]. 控制与决策, 2023, 38(6): 1491-1509.

Survey of lane detection for autonomous robots in semi-structured scenarios

SU Xiao-jie[†], LIU Xing-yu, LI Rui, TAN Wei, GAO Shen-zhen

(School of Automation, Chongqing University, Chongqing 400044, China)

Abstract: Visual perception for autonomous robots is one of the key technologies to realize robot-environment interaction. Lane, as a kind of geometry information to ensure the safety of robot motion, has a wide research value, and lane detection in semi-structured scenarios brings new challenges to this area. The conventional method based on classic feature extraction process does not show robustness for non-urban environments or complex scenarios that have only degenerate geometric features. The use of deep learning methods for lane detection has become a mainstream trend. In this paper, we review the research on visual edge detection for mobile robots in semi-structured scenarios, and the application prospect and effect of the lane detection algorithm in semi-structured scenarios are investigated. First, the common edge line detection datasets are organized, and the current datasets and the focus of the research are analysed from the perspective of acquisition scenarios and annotation types. Second, different methods are classified and summarized, and the detection and data processing processes of different methods are compared. Then, the commonly used evaluation metrics of deep learning are sorted out, and the detection results of different methods in the face of different scenarios are compared and analyzed. Finally, the research direction of the edge detection method based on deep learning is prospected for the problems of visual lane detection in semi-structured scenes.

Keywords: visual perception; lane detection; semi-structured scenarios; deep learning; dataset; evaluation metric

0 引言

实现面向机器人自主运动的场景感知是机器人与外界交互所需要解决的必要难题. 边线检测^[1]作为感知技术的重要组成部分, 能够帮助无人车或移动

机器人更好地理解环境, 为可能发生的危险状况(如紧急变道、道路消失和急转弯等)做好准备. 随着深度学习^[2]的飞速发展, 基于视觉的边线检测已取得了重大突破^[3], 但仍存在局限性. 例如, 多种边线检测算

收稿日期: 2022-09-22; 录用日期: 2023-03-11.

基金项目: 国家重点研发计划政府间合作重点专项项目(SQ2019YFE011667); 国家自然科学基金项目(62003059); 广东省重点领域研发计划项目(2020B0909020001); 中国博士后基金项目(2020M673136); 重庆市留创计划项目(2205012983768768).

[†]通讯作者. E-mail: suxiaojie@cqu.edu.cn.

法在高速公路、城市道路等场景中已取得比较理想的检测效果,能够快速、准确地识别、定位车道,但在环境特征复杂、道路标记缺失等情况下,边线检测仍是一项非常具有挑战性的任务^[4]。

针对机器人自主运动任务,结构化场景通常指通行信息明确的场景,这些场景往往拥有清晰、规范的道路标记与明显的几何特征,容易识别。例如,高速公路、城市道路等,都属于比较常见的结构化场景(如图1(a)所示)。与之相对,非结构化场景通常指通行信息缺失或不明确的场景,这些场景中的路面内、路面外图像对比度很低,没有清晰、规范的道路标记,也没有明显的几何特征,甚至道路的整体形状也可能是任意的^[5]。例如,一些人迹罕至区域、自然灾害区域等,属于非结构化场景(如图1(c)所示)。这类场景大多不具备移动机器人(尤其是轮式移动机器人)通行条件,因此许多工作不考虑这类场景下的边线检测任务。半结构化场景指介于结构化场景与非结构化场景之间的特殊场景,这类场景既存在类似结构化场景下的部分通行信息、道路标记与几何特征,又可能因场景修缮不完整、受到自然或人为因素破坏等原因,无法完整、准确地提供结构化场景可提供的全部信息^[6]。例如,乡村道路、大学校园内部道路等,可认为是半结构化场景(如图1(b)所示)。这类场景常具有比规范的城



(a) 结构化场景



(b) 半结构化场景



(c) 非结构化场景

图1 3种机器人自主运动场景示例

市道路更复杂的路面状况,部分道路可标记但不规范或不完整^[7],当经历风暴、雨雪等恶劣天气后,场景的视觉特征可能发生比较剧烈的变化。

对于移动机器人(尤其是轮式移动机器人,如无人车)而言,相对于结构化场景与非结构化场景,其在半结构化场景下的自主运动需求更为广泛;而移动机器人在半结构化场景下的自主运动能力的增强,可使得机器人对场景的适应性更强,从而进一步提升机器人作业能力的泛化性。上述原因使得当前面向机器人自主运动任务的视觉边线检测成为一个主要的研究方向^[8]。

本文拟针对半结构化场景下移动机器人视觉边线检测任务,从边线数据集、边线检测方法、边线检测方法指标与性能分析3方面,对现有视觉边线检测算法进行整理、对比、分析与评价,进而提出当前半结构化场景下视觉边线检测研究所面临的问题与挑战,为后续相关研究提供参考。

1 边线检测数据集

有效的训练和测试数据集是深度学习发展的基础^[9],也是衡量视觉感知技术检测效果的重要工具之一。近期,许多边线检测数据集被提出,根据其提供的标注信息的特点可分为3类:2D车道数据集、3D车道数据集以及能够实现其他视觉任务(场景分割、行人检测等)的边线检测场景数据集^[10]。本章将对这些数据集进行简介与分析。

1.1 2D车道数据集

大多数基于视觉的边线检测方法都专注于将边线检测描述为2D任务,即通过二维图像上的参数化曲线或像素点标记图像上的边线信息。目前,2D车道数据集是收集和使用最为广泛的数据集类型之一,常见的2D车道数据集如下:

1) TuSimple^[11]于2017年发布,采集于照明条件稳定且天气状况良好的高速公路场景,车道线清晰,且包含多种交通驾驶场景,如相邻车道车辆的遮挡、不同的交通道路标记以及从2车道到4车道甚至更多数量车道的路况。其中训练集为3 626个视频序列,每个序列包含1 s内收集的20个连续帧,且最后一帧带有车道标注。

2) CULane^[12]于2018年发布,是目前规模最大且场景最为丰富的边线检测数据集,采集于不同天气状况与照明条件下的北京城区,其中包含拥挤、弯曲、眩光以及夜晚等9种车道场景,也是最具有挑战性的数据集之一。共收集超过55 h的视频序列,合计133 235帧。

3) LLAMAS^[13] 是2019年发布的数量超过10万带车道标注的无监督数据集,采集于高速公路场景.该数据集利用自动创建的地图将车道标记投射到传感器采集的图像中,并通过进一步的优化程序提高其准确性.另外,该数据集包含了像素级注释的虚线车道标记.

4) CurveLanes^[14] 由大约15万张车道图像组成,其中90%以上为曲线车道,这为弯曲车道的检测做出了贡献.另外, CurveLanes 还包含多种路况,如S车道、Y车道以及多车道场景等.

TuSimple 和 CULane 是目前使用最为广泛的两种边线检测数据集.除了以上4种数据集外,现有的2D车道数据集还包括 VPGNet^[15]、DET^[16]、CalTech Lanes^[17]、VIL-100^[18]、Comma2k19-LD^[19] 和 SDLane^[20] 等.

1.2 3D车道数据集

3D数据集是将边线用三维点云进行表示的数据集.要采集3D数据集,需要具有可以采集图像深度信息的传感器,如深度相机或激光雷达.相比于2D数据集,3D数据采集对设备要求更高,对边线信息进行标注所需花费的人工成本也更高.目前,常见的3D车道数据集如下:

1) OpenLane^[21] 是第1个大规模且采自真实场景的3D车道数据集,包含了实用性强的车道标注和邻近目标(closest-in-path object, CIPO)标注.该数据集还展现出场景多样性,共包含14种车道类型(双黄实线、单白实线和虚线等),合计超过20万帧车道图像.

2) ONCE-3DLanes^[22] 相比以往发布的其他数据集是目前规模最大的、采自于真实场景的3D车道数据集,包含不同的天气状况(晴天、雨天)和照明条件(白天、黑夜),合计21.1万帧图像,并带有3D车道标

注.

1.3 交通场景数据集

除车道数据外,交通场景数据集还包括其他可用于视觉感知技术的标注数据,如道路标记、可行驶区域、车辆和行人等,常见的交通场景数据集如下:

1) BDD100K^[23] 是由加州大学伯克利分校发布的用于计算机视觉的规模最大、内容最具多样性的公开交通场景数据集,采集于一天中的不同时间和不同天气状况下,包含10万段高清视频,在每段视频的第10s对关键帧进行采样,以此获得10万张图像,并且使用2D边界框标注行人、车辆、道路标记和可行驶区域等.

2) KITTI^[24] 是最知名的自动驾驶数据集之一,该数据集场景包含城市道路和农村地区,每张图像最多可显示15辆汽车和30名行人,且能够体现自动驾驶中可能遇到的实际状况,如遮挡等. KITTI数据集广泛应用于计算机视觉领域的光流、视觉测距、3D物体检测以及3D跟踪等方面.

3) CityScape^[25] 主要采集于德国的中大型城市以及瑞士苏黎世,是最权威、最具有专业性的语义分割数据集之一. CityScape 包含5000张经过精确标注的图像以及20000张经过粗略标注的图像,但是车道并没有详细的标注信息. CityScape 广泛应用于图像的像素分割与实例分割等方面.

除以上几种数据集外,现有的交通场景数据集还包括 ApolloScape^[26]、CamVid^[27]、Mapillary^[28]、TRoM^[29] 和 Road Marking^[30] 等.

1.4 现有边线检测数据集分析

对当前边线检测相关的数据集进行整理与对比,结果如表1所示.

表1 边线检测数据集综合对比

数据集	发布时间	分辨率	数量	道路场景	车道标注	标注类型
TuSimple ^[11]	2017	1280×720	6408	高速公路	是	曲线
CULane ^[12]	2017	1640×590	133235	城区、高速公路	是	曲线
LLAMAS ^[13]	2019	1276×717	100042	高速公路	是	像素
CurveLanes ^[14]	2020	2650×1440	150000	城区、高速公路	是	曲线
VPGNet ^[15]	2017	640×480	21097	城区、高速公路	是	曲线
DET ^[16]	2020	1280×800	5424	城区、高速公路	是	像素
CalTech-Lanes ^[17]	2008	640×480	1225	城区、高速公路	是	曲线
VIL-100 ^[18]	2021	1920×1080	10000	城区	是	曲线
BDD100K ^[23]	2018	1280×720	100000	城区、高速公路	是	曲线
KITTI ^[24]	2013	1242×375	579	城区	是	像素
CityScape ^[25]	2016	2048×1024	25000	城区	否	—
ApolloScape ^[26]	2018	3384×2710	143906	城区、高速公路	是	像素点云
CamVid ^[27]	2008	960×720	701	城区	是	像素
TRoM ^[29]	2017	1280×960	712	城区、高速公路	是	曲线

可以看到,当前边线检测数据集具有以下特点:

1) 随时间发展,边线检测数据集呈现出分辨率逐渐提高,数据集数量和道路场景逐渐丰富、全面的变化趋势;2) 目前的边线检测数据集主要针对无人驾驶、辅助驾驶等无人车系统,为了使无人车能在更多复杂路况上行驶,部分数据集考虑了不同的天气状况(晴天、雨天)、照明条件(白天、黑夜)以及道路拥挤状况(通畅、遮挡、拥挤)等;3) 目前的边线检测数据集全部采集自高速公路、城市道路等结构化场景.在本文调研过程中,没有发现专门针对半结构化场景采集的数据集,或是专门用于半结构化场景的边线检测算法.

如引言所述,现有边线检测数据集虽然对结构化场景有较好的覆盖,可以测试自动驾驶或辅助驾驶系统对于边线检测算法的鲁棒性,以及各类环境的适应能力,但目前为止还鲜有工作对更广泛的半结构化场景开展数据采集工作.半结构化场景边线检测数据集可以为形成更具泛化性的无人驾驶或辅助驾驶算法提供初步验证资料.

2 边线检测方法的研究进展

先进驾驶辅助系统(advanced driving assistance system, ADAS)^[31]由车道保持辅助(lane keep assist, LKA)、自适应巡航控制(adaptive cruise control, ACC)^[32]和车道偏离预警(lane departure warning, LDW)等一系列子应用组成,其在近20年的飞速发展极大地方便了人类的日常出行.由于真实场景的复杂性,ADAS的安全性成为最基本、最关键的因素之一,而这需要从运动轨迹预测^[33]、边线检测、相邻前车检测^[34]以及避免碰撞^[35]等多个技术方面来解决.因此,精确的边线检测有助于有效理解交通场景,并引导机器人自主运动到达车道内的适当位置^[36].另外,除了智能驾驶,边线检测也有助于机器人导航^[37]和轨迹规划^[38].

下面将分别对传统的边线检测方法与基于深度学习的边线检测方法进行描述和分析.

2.1 基于手工提取特征的边线检测方法

传统的边线检测方法通常依靠手工操作提取底层特征,通过检测标记的形状和曲线拟合解决边线检测的问题,步骤如下:

1) 通过预处理过滤无关特征,保留与车道有关的特征.常用的方法有逆透视变换(inverse perspective mapping, IPM)^[17,39-41]、均值滤波、定向可控滤波^[42]和颜色空间转换(灰度化^[43]或YCbCr^[44])等.值得一提的是,文献[40]最早尝试使用立体视觉系统的边缘提取算法检测车道和障碍物.

2) 提取车道特征.常用方法有尺度不变特征变换(scale-invariant feature transform, SIFT)^[44]、Canny算子^[45-46]、haar-like^[47]和局部二值模式(local binary pattern, LBP)^[48]等.此外,一些方法还提出采用模板匹配^[49-50]、决策树^[51]、支持向量机(support vector machine, SVM)^[52-53]等学习机制.

3) 通过拟合的方法对提取的车道特征进行后处理,滤除误检以形成最终车道.常用的方法有霍夫变换^[54-64]、随机抽样共识(random sample consensus, RANSAC)^[52,65-66]、B样条拟合^[67-68]和卡尔曼滤波器^[41,52,69]等.

此外,文献[70]提出了一种基于手工提取脊线特征的边线检测方法,文献[71-73]提出了基于手工提取颜色特征的边线检测方法,文献[40,60-62,74-76]开展了手工提取边缘特征的边线检测方法研究.车道的其他可用特征可参见文献[77].除上述方法外,传统的边线检测方法还包括文献[78-85],这些方法均是依靠高度专业化的手工特征提取和启发式算法的组合来识别车道.

总体而言,传统方法的本质是以自底向上的方式工作,通过图像处理获得视觉线索,进而完成对车道的检测^[86].但是,传统方法的成功建立在大量的启发式算法和复杂的后处理的基础上,在确定车道的最终位置时还包含了主观的几何假设^[87].因此,传统边线检测方法只适用于拥有清晰道路标记的结构化场景,在面对非结构化场景或一些极端路况时,由于特征缺乏足够的鲁棒性,算法效果会受到严重影响,造成其在上述场景下并不适用.

2.2 基于深度学习的边线检测方法

传统方法很难在真实车载场景中保持鲁棒性,这是因为基于手工算子提取特征的检测模型无法应对不同场景的边线多样性.最近几年,大部分边线检测方法已集中于深度学习,其能够学习不同层次的特征,展现出的鲁棒性和实时性突破了传统方法的局限性.

卷积神经网络(convolutional neural network, CNN)是一种拥有出色的特征提取与分类能力的神经网络,已被证明在许多大型数据集(ILSVRC^[88]和Pascal VOC^[89])上的目标检测和分类是有效的.近年来,GPU、FPGA等计算硬件的不断发展也为CNN在边线检测中的应用提供了便利,在大规模数据集出现之前,文献[90]最早尝试将基于CNN的深度学习方法应用于边线检测.

本节将以检测原理作为分类依据,对基于CNN

或其他深度神经网络的边线检测方法进行讨论。

2.2.1 基于分割的检测方法

基于分割的方法是深度学习中最常见的边线检测方法,它将边线检测视为逐像素分类问题,首先利用语义分割对像素点进行二分类,并判断每个像素点属于车道还是背景;然后对车道像素点进行聚类以生成不同的车道实例。

传统基于CNN的图像处理方法存在一定的局限性,需要花费大量的时间遍历整张图像或者感兴趣的区域(region of interest, ROI),获得能够用于训练和测试的小块图像,图像的选取尺寸若不恰当,则易导致丢失局部信息或计算规模过大。另外,这类方法还存在冗余计算以及车道相互位置信息缺失等问题。文献[91]结合CNN和RANSAC,获取ROI作为CNN的输入,并通过全连接多层感知器(fully connected multilayer perceptron, MLP)输出最终图像。文献[92]以各像素点为中心确定小块图像,用于语义分割区分像素点的类型。文献[93]受金字塔场景分析网络^[94](pyramid scene parsing network, PSPNet)的启发,令全景图像和原始图像的多个切片面共同作为CNN的输入,获得不同尺度的特征。这些方法虽然能够在一定程度上应对复杂的半结构化场景,但依然存在可完善之处。

为了更有效地利用视觉信息,SCNN^[12]将边线检测视为多类分割问题,并将传统CNN的逐层卷积替换为特征图内的切片卷积操作,类似于循环神经网络(recurrent neural network, RNN),很好地利用了像素点的空间信息,使得信息流能够在图像的行与列之间传递,适合检测车道等长而连续的目标,但这种方法应用速度慢,长距离传递有可能导致信息丢失。RESA^[95]延续了SCNN的思路,以不同步长传递切片间的信息,并且通过循环移动特征图内的切片垂直和水平地聚合信息,增加并行处理能力,降低时间成本。SpinNet^[96]通过一种旋转卷积层提取并融合不同角度方向的特征,与SCNN和RESA相同,适用于检测车道这类长窄目标。

文献[97]提出的全卷积网络(fully convolutional networks, FCN)使用卷积层替代全连接层,能够处理任意尺寸大小的输入样本,规避了全连接层只能处理固定尺寸大小样本的局限性。与FCN的逐点相加不同,拥有对称结构的U-Net^[98]采用通道维度拼接的特征融合方式保留了特征之间的相关性,允许上下文信息向更高分辨率的图层传播,并且能够在样本数量不大的情况下获得较好的分割效果,文献[99-101]的边

线检测方法借鉴了这种思想。

生成对抗网络^[102](generative adversarial networks, GAN)是无监督学习中最具前景的方法之一,由生成器和鉴别器两个CNN组成,两个网络的相互竞争最终会形成一种平衡:前者生成近似真实的数据,后者很难在这些数据与实际样本间做出判断。Ripple-GAN^[103]通过集成特征融合、Wasserstein GAN以及多目标语义分割,在复杂路况以及车道模糊的半结构化场景下有着较好的检测性能。SIM-CycleGAN^[104]利用CycleGAN增强了模型在弱光条件下的检测性能。EL-GAN^[101]的生成器为U-Net结构,鉴别器为DenseNet^[105]结构,获得了结构丰富的语义分割结果。

长短期记忆网络^[106](long short-term memory, LSTM)作为RNN的一种变体,在遗忘不重要信息与记住基本特征方面的性能优于传统RNN模型,LSTM与CNN相结合所拥有的强大网络推理能力已被应用于边线检测领域。FusionLane^[107]使用激光雷达点云转换而成的车道鸟瞰图作为语义分割对象,同时使用ConvLSTM^[108]的时序信息帮助网络获得了较好的预测结果。文献[109]在编码器与解码器之间加入两层LSTM,实现了性能的提高,尤其是在面对严重遮挡与恶劣天气的情况下,文献[110]也使用了相似的网络结构。结合CNN和LSTM对车道结构的几何信息进行处理的方法还有文献[111]。

在计算能力有限的情况下,注意力机制的提出能够对任务所需的计算资源进行分配,对特征图中的特征按照重要性分配不同的权重。SAD^[112]提出一种自我注意力蒸馏的方法用于车道分割任务,集成自我注意与知识蒸馏的思想增强上下文信息的相关性,该模型能够在面对半结构化道路等具有挑战性的场景时,从自身学习并改进,不需要额外的监督与标记数据。SALMNet^[113]和文献[114]同样借鉴注意力机制来增强车道的结构特征。

LaneNet^[115]和文献[116]将边线检测视为对二值段进行聚类以实现实例分割的问题。LaneNet同时利用二值分割和特征嵌入区分车道实例,具体表现为:网络的两个分支分别实现语义分割和以向量形式表示像素点,然后对结果进行聚类并输出,缺点是聚类的结果存在一定的随机性且实时性较差。LaneAF^[117]利用深层聚合网络^[118](deep layer aggregation, DLA)进行特征提取,DLA通过借鉴DenseNet和特征金字塔网络^[119](feature pyramid networks, FPN)实现了同时聚合语义信息和空间信

息, LaneAF 定义的两组关联字段(水平和垂直)可以看作一个向量场或向量函数,能够给图像的每个像素点分配一个单位向量,进而识别和分割独特的车道实例. LaneNet 和 LaneAF 均不受预先确定的车道数量的约束,即能够应对半结构化场景中可能出现的车道数量变化的情况. RONELD^[120]对分割结果使用加权最小二乘线性回归来对破损的车道边缘进行修复,进而提升检测性能,这在半结构化场景中非常必要. 文献[121]提出的网络集成了语义分割和光流估计的思想,以此探索帧内车道的位置规律,提升分割速度,同时能够应对半结构化场景中路况易变化的特点. DAGMapper^[122]提出了一种能够应对复杂路况(如分叉线)的离线边线检测方法,但是缺乏能够实时处理复杂拓扑车道线感知的研究方法.

文献[123]使用多任务网络结构进行边线检测,模型由5个任务分支组成,其中二值分割分支和车道像素嵌入分支用于将提取所得的车道像素分类为不同的车道实例. 类似于 LaneNet^[115],可行驶区域分支对可行驶的道路做出指示,而车道点回归分支能够细化二值分割的输出,获得每个车道点的位置. RBNet^[124]通过建立贝叶斯模型,对像素点所属类别进行估计,同样实现了对车道和可行驶区域的检测. 文献[125]也提出了一种新的多任务融合网络架构,通过热图回归预测获得车道消失点,进而对车道进行检测. 考虑到多任务网络结构通常需要复杂的后处理步骤来聚合每个分支的输出结果,文献[126]提出了一种基于两个级联 CNN 的端到端车道识别、聚类以及分类系统,以此替代多任务网络结构分支,缺点是效率较低.

除了上述提到的深度神经网络外,目前还存在一些发展较为成熟的网络结构,并且已普遍应用于边线检测. 例如, ResNet^[127]利用类似电路“短路连接”的残差学习解决了更深网络可能出现的性能退化问题,成为深度学习领域的里程碑式网络. 基于 ResNet 的 E-Net^[128]能够在一定程度上平衡精度与速度,使卷积层与池化层以并联的方式运行,节省计算参数,减少计算量. ERFNet^[129-130]将残差模块与分解卷积相结合,在更加高效的同时保持了准确性. 另外, EDANet^[131-132]和 RefineNet^[133]也可用于边线检测,在提升检测效率的同时保持检测精度^[134].

总体而言,考虑到语义分割与实例分割的性质,基于分割的边线检测方法需要对每个像素点进行分割,但是大部分像素点只是背景,因此会出现大量的冗余计算,并且往往需要后处理步骤对车道像素点进

行聚类,这些因素会导致内存成本的提高以及计算规模的增大,进而影响检测效率. 其次,基于分割的方法并不能充分利用车道的先验信息,并且在面对严重遮挡与极端光照的情况下不能表现出足够的适应性,影响其半结构化场景下的检测性能.

2.2.2 基于锚点的检测方法

基于锚点的检测方法最先来源于目标检测 Faster R-CNN^[135],首先由预定义的锚点生成候选框,然后通过候选框对待检测目标进行分类和定位. 在边线检测中,考虑到车道所拥有的独特形状(细长杆状)设计出线段形状的锚点,并在采样点与预设锚点之间回归偏移量. 具体而言,首先定义一组起点与方向不同的直线作为锚点;然后通过预测偏移量将锚点回归到车道上;最后选择置信度最高的车道作为检测结果.

基于锚点的边线检测方法可以分为基于线锚的方法和基于行锚的方法,前者使用预定义的线锚对车道进行回归,后者则是对图像上每个预定义行上的单元格进行预测,得到每一行可能含有车道的位置. 下面对两类方法进行具体说明.

1) 基于线锚的检测方法.

文献[136]是将 Faster R-CNN 基于锚点的目标检测方法应用于边线检测的最早尝试之一,它对 Faster R-CNN 的锚点生成框架进行扩展,使其更适用于小目标的检测任务,进而尝试检测具有细长特征的目标. 但是基于候选区域的锚点并不适用于检测车道,因为这种方法没有考虑到车道结构的连续性以及同一车道不同部分之间的相关性.

Line-CNN^[137]是将线锚应用于边线检测的开创性工作,将 Faster R-CNN 中的候选区域替换为候选线,使其与车道细长杆状的特征相契合,同时将二阶段的检测过程转化为一阶段检测过程(类似目标检测的 YOLOv3^[138]和 SSD^[139]). 具体而言,与区域候选网络(region proposal network, RPN)类似,Line-CNN 通过提出的线段候选单元(line proposal unit, LPU)生成一组具有特定方向的候选线 LP 作为锚点,进而对车道准确位置进行回归. 考虑到车道通常起始于图像左侧、右侧以及底部,只需在特征图这3个边界生成所需的 LP. 最后采用非极大值抑制(non-maximum suppression, NMS)的后处理方法减少冗余信息,使得预测结果更加准确. LaneATT^[140]采用与 Line-CNN 相同的 LP 类型,同时提出了一种新颖的基于锚点的注意力机制来聚合车道全局信息,并辅助推断车道的位置,在多个数据集上展现了出色性能.

与Line-CNN和LaneATT不同,PointLaneNet^[141]使用与图像底部垂直的线段作为锚点,首先将待处理图像划分为 $W \times H$ 的网格图,使得每个网格最多容纳一个车道点,在经过特征提取后进行密集回归,即预测每个车道点相对于网格中心点的偏移量、垂直方向的起始点以及相关的置信度得分。但是其采用NMS的后处理步骤来过滤置信度较低车道的方法可能并不适用于弯曲车道,因为对不同层次特征的预测不能采用相同的策略,网格中心点附近车道点的偏移量往往能被精确预测,但较远点的偏移量则会存在偏差。对此,CurveLane-NAS^[14]在文献[142]的启发下引入网络架构搜索(neural architecture search, NAS),集成了多尺度后处理策略的NAS框架,不仅可以探索最合适的特征提取网络,还能充分利用不同尺度的局部特征和全局特征,实现半结构化场景下的弯曲边线检测,但这种方法会大量占用GPU的工作时间。

Line-CNN通过生成LP来定位车道的方法需要预先学习车道的实际特征,额外出现的计算量与相关参数的设置影响了泛化性。为此,SGNet^[143]提出了一种自顶向下的通过车道消失点引导的锚点生成机制,能够对消失点进行预测,进而产生相应的密集锚点,并且使用多级结构约束进一步提升感知性能,以此实现对车道的精确定位。文献[20]提出特征车道的概念对弯曲车道与直线车道等结构不同的车道进行描述,首先利用奇异值分解对训练集的车道矩阵进行处理以获得特征车道;然后通过特征车道空间对训练聚类生成LP集合。其提出的基于锚点的检测网络SIIC-Net不仅能够确定每个LP的偏移量,而且将车道之间的相关性考虑在内,使其能够有效应对复杂的路况。

2) 基于行锚的检测方法。

基于行锚的检测方法将边线检测描述为逐行分类的任务,模型将预测每一行可能包含车道的位置。虽然这种方法需要输出每个像素的所属类别,但这种“分而治之”的策略能够在保持精度的同时减少计算量,提高检测效率,同时也需要后处理策略来提取车道实例。

UFLD^[144]将边线检测视为一个基于全局特征的行选择问题,即通过全局特征选择图像在预定义行上的车道位置,这与实例分割不同,因此不仅有效降低了计算量,而且拥有整个图像的感受野范围,使其能够应对严重遮挡与极端光照的环境。另外,UFLD还首次提出相应的结构损失函数,很好地利用了车道的先验信息。由于行锚难以定位水平车道,而

列锚在定位垂直车道时存在偏差,此UFLDv2^[145]在UFLD的基础上进行扩展,提出了一种混合锚点系统(包括行锚和列锚),在保持高效的同时有效降低了定位误差,提高检测精度,同时也提出了相应的损失函数。为了进一步完善检测后车道的实例区分问题,CondLaneNet^[146]提出了受条件卷积实例分割^[147](conditional convolutions for instance segmentation, CondInst)和SOLOv2^[148]启发的条件边线检测策略,这种自顶向下的边线检测框架首先检测车道实例并为每个实例输出一组动态内核参数,然后逐行且动态地预测每个实例的行方向位置、垂直范围以及偏移量,进而描述车道形状。E2E-LMD^[149]提出了一种端到端逐行分类的边线检测方法,通过设计的水平缩减模块对特征图的水平分量进行压缩,即对宽度降维,提取到精简的行方向上从左向右扩散的车道信息,最终输出当前行上车道的置信度以及坐标,这种方法不需要复杂的后处理步骤。IntRA-KD^[150]进一步采用与文献[112]相似的知识蒸馏的方法对边线检测进行完善,通过构建区域间亲和力图来更有效地将车道之间的结构关系从教师网络模型转移到学生网络模型,因此相比于其他蒸馏方法,IntRA-KD能够更充分地利用车道之间的相关性,很好地区分形状相似但功能不同的目标。

对于基于锚点的边线检测方法,由于锚点的形状是预先确定的,可以很好地应对遮挡和光照等无视觉线索的情况,这对半结构化场景下的边线检测是有利的,但这种特性也使得该方法在面对多种形状车道时并不能灵活应对,强形状先验限制了锚点描述各种不同形状车道的能力,即自由度较低。

2.2.3 基于关键点的检测方法

受到人体姿态估计^[151-152]方法的启发,一些学者研究对车道的关键点进行估计以及对关键点之间的相关性进行分析,以此实现对车道的检测。这种自底向上的检测方法将边线检测看作离散关键点的检测和关联问题,具体而言,首先将车道建模为由一组关键点连接而成的曲线,在每个关键点处对其与下一个关键点之间的偏移量进行预测,依次迭代,最后获得整条车道的关键点集合。

作为最早将边线检测建模为多关键点估计和关联问题的方法,FOLOLane^[153]对车道的局部几何结构进行建模,采用自底向上的方式实现对全局结构的预测,即预测每个关键点与其领域之间的偏移量并分组,再将关键点一一相连形成完整车道。GANet^[154]

对关键点采用全局回归而非局部回归的方式,即每个关键点直接回归到所属车道的起点,而不是采用 FOLOLane 的逐点扩展方式,同一车道不同关键点的并行处理有效提升了效率,且更具有鲁棒性. PINet^[155] 将预测关键点的聚类问题转化为实例分割问题,首先通过一种用于人体姿态估计的堆叠沙漏网络^[156] 对车道关键点位置的置信度、偏移量和嵌入特征进行预测,然后根据嵌入特征之间的相关性对车道实例进行聚类,但是 PINet 在面对有遮挡的路况时存在局限性.

基于关键点的检测方法可以灵活地描述多种形状的车道,并且在一定程度上兼顾了实时性与准确性,能够适应半结构化场景下的行车环境. 全局匹配的关键点回归方式很好地利用了全局视野,不会出现错误逐渐累积的情况,但是在面对遮挡或光照时如何构建全局信息则是应当优化的方向.

2.2.4 基于多项式曲线拟合的检测方法

基于多项式曲线拟合的边线检测方法首先通过多项式表示车道曲线,然后对多项式的参数进行预测,最终输出通过完整的曲线方程表示的车道.

作为通过神经网络对车道曲线方程进行回归的开创性工作, PolyLaneNet^[157] 将驾驶车辆前视摄像头采集到的图像作为输入,利用多项式表示车道曲线,并输出图像中每条车道的多项式方程. 文献[158]提出了一种可微的最小二乘拟合模块来检测车道,得到相关的最小二乘拟合参数. 文献[159]提出的 PRNet 框架不仅回归得到车道的多项式参数,而且能够获得每条车道的起始检索点和终点. LSTR^[160] 在通过多项式回归车道曲线的过程中引入 Transformer^[161] 模块,获得了超过 420 fps 的检测速度. 文献[162]使用易于计算且稳定的三次贝塞尔曲线对车道曲线进行拟合,其拥有比三阶多项式更好的拟合能力,同时提出了一种

表 2 部分边线检测方法概括总结

检测方法	特征提取网络	预处理	后处理	损失函数	数据集
Cascaded-CNNs ^[126]	ERFNet	No	No	交叉熵	TuSimple
FusionLane ^[107]	Xception	Yes	No	交叉熵	其他
Heatmap-based ^[125]	ERFNet	数据增强	No	交叉熵、 L_2	CULane
LaneAF ^[117]	DLA	No	Yes	交叉熵、 L_1 、IoU 损失	TuSimple、CULane、LLAMAS
LaneNet ^[115]	E-Net	逆透视变换	最小二乘拟合	合页损失	TuSimple
文献[116]	ResNet	数据增强	Yes	合页损失、交叉熵、Smooth L_1	CityScape
RESA ^[95]	ResNet、VGGNet	No	No	交叉熵	TuSimple、CULane
SAD ^[112]	E-Net	数据增强	Yes	交叉熵、 L_2 、IoU 损失	TuSimple、CULane、BDD100K
SCNN ^[12]	VGGNet	No	Yes	交叉熵	TuSimple、CULane、CityScape
SIM-CycleGAN ^[104]	ERFNet	No	No	生成对抗损失	CULane
VPGNet ^[15]	CNN	No	Yes	交叉熵、 L_1	Caltech-Lanes、VPGNet
CLRNet ^[168]	ResNet、DLA、FPN	Yes	No	焦点损失、Smooth L_1	TuSimple、CULane、LLAMAS
LaneATT ^[140]	ResNet	数据增强	非极大值抑制	焦点损失、Smooth L_1	TuSimple、CULane、LLAMAS
Line-CNN ^[137]	ResNet	数据增强	非极大值抑制	Smooth L_1	TuSimple
PointLaneNet ^[141]	CNN	数据增强	非极大值抑制	交叉熵、 L_2	TuSimple、CULane
SGNet ^[143]	ResNet	逆透视变换	No	交叉熵、Smooth L_1	TuSimple、CULane
CondLaneNet ^[146]	ResNet、FPN	No	No	焦点损失、交叉熵、 L_1	TuSimple、CULane、CurveLanes
E2E-LMD ^[149]	ERFNet	数据增强	No	交叉熵	TuSimple、CULane
IntRA-KD ^[150]	ERFNet、E-Net、ResNet	No	No	交叉熵	ApolloScape、CULane、LLAMAS
UFLD ^[144]	ResNet	数据增强	No	交叉熵、 L_1	TuSimple、CULane
UFLDv2 ^[145]	ResNet	数据增强	No	交叉熵、Smooth L_1	TuSimple、CULane、CurveLanes、LLAMAS
FOLOLane ^[153]	ERFNet、BiSeNet	数据增强	No	L_1	TuSimple、CULane
GANet ^[154]	ResNet、FPN	数据增强	Yes	焦点损失、 L_1 、Smooth L_1	TuSimple、CULane
文献[158]	ERFNet	No	最小二乘拟合	L_2	TuSimple
FastDraw ^[169]	ResNet	No	Yes	自回归损失	TuSimple、CULane
LSTR ^[160]	ResNet	数据增强	No	L_1	TuSimple
PolyLaneNet ^[157]	ResNet	数据增强	No	交叉熵、 L_2	TuSimple、LLAMAS
PRNet ^[159]	BiSeNet	数据增强	No	Smooth L_1	TuSimple、CULane
BezierLaneNet ^[162]	ResNet	数据增强	No	交叉熵	TuSimple、CULane、LLAMAS
CooNet ^[170]	CNN	No	No	L_1 、 L_2	TuSimple
文献[114]	ResNet	No	No	交叉熵	TuSimple、CULane
MMA-Net ^[18]	ResNet	No	No	交叉熵、IoU 损失	VIL-100

新颖的特征翻转融合模块,能够有效模拟实际车载场景的对称性.基于多项式曲线拟合的检测方法其检测效果易受多项式参数的影响,参数的预测误差将导致所预测车道形状的误差,因此该方法虽然能够达到较高的检测速度,但是难以获得较高的检测精度.

除以上针对2D车道进行检测外,不少研究已实现了对3D车道的检测.例如,3D-LaneNet^[163]首次使用车载传感实现了从单一图像预测道路场景中车道的3D布局,3D-LaneNet+^[164]和Gen-LaneNet^[165]则是在3D-LaneNet基础上的进一步扩展,其他3D边线检测方法还包括文献[166-167].

为了能够更加直观地了解每种检测方法的具体信息,对以上提到的部分边线检测方法进行概括总结,如表2所示,主要包括每种检测方法的特征提取网络、是否进行预处理和后处理、所存在的损失函数类型以及性能测试所用的数据集.其中: L_1 为平均绝对误差, L_2 为均方误差.

在预处理方面,考虑到半结构化场景下车道容易出现不固定、不连续等特点,同时为了避免训练集过拟合的状况,由旋转变换、翻转变换、平移变换、缩放

变换以及灰度变换等操作组成的数据增强方法是常用的预处理方式,以此扩充数据集的规模,提高泛化性,这对于解决目前半结构化场景数据集较少的问题是有帮助的.而当移动机器人工作在半结构化场景时,其前视摄像头所采集的图像中,原本处于平行状态的车道边线会因为透视效应呈现相交的画面,因此能够消除此类效应的逆透视变换IPM也是自动驾驶与辅助驾驶中重要的预处理方式.

在后处理方面,当面对具有复杂路况的半结构化场景时,定位遗漏与定位重叠的情况时有发生,因此能够寻找最佳定位目标、消除冗余信息的非极大值抑制NMS方法至关重要,尤其是对于基于锚点的边线检测方法,如Line-CNN^[137]、LaneATT^[140]和PointLaneNet^[141].

总体而言,根据目前的边线检测研究进展,部分算法已拥有能够适应半结构场景下边线检测任务的有效功能.例如,基于分割方法的RESA^[95]在SCNN^[12]的基础上,使用循环特征聚合模块实现了信息的有效传递,即在垂直和水平方向上收集车道全局信息,适用于目标外观线索较弱的半结构化场

表3 部分边线检测方法在半结构化场景下的应用前景

检测方法	核心思想	应用优势(半结构化场景)
SCNN ^[12]	切片卷积	检测具有空间关系但外观线索较弱的目标
CurveLane-NAS ^[144]	NAS	具有较好的弯道检测性能
RESA ^[95]	循环特征聚合	检测具有空间关系但外观线索较弱的目标
SpinNet ^[96]	旋转卷积	提取和融合多个方向的有用特征
Ripple-GAN ^[103]	GAN	应对车道标记信息不完整的情况
文献[109]	LSTM	应对严重遮挡与恶劣天气的情况
SAD ^[112]	自注意蒸馏	从自身学习并显著改进检测效果
LaneNet ^[115]	多任务网络	处理不同数量的车道以及应对车道变化
LaneAF ^[117]	关联字段	处理不同数量的车道以及应对车道变化
RONELD ^[120]	最小二乘线性回归	对破损的车道边缘进行修复
文献[121]	光流估计	应对路况易变化的情况
DAGMapper ^[122]	DAG	应对分叉线、密集线等复杂路况
AgnosticLane ^[123]	多任务网络	应对车道标记出现变化的情况
Heatmap-based ^[125]	基于消失点	应对可能出现的道路消失的情况
LaneATT ^[140]	基于锚点	应对遮挡以及缺少车道标记的情况
PointLaneNet ^[141]	车道回归	应对可能出现的道路消失的情况
SGNet ^[143]	基于消失点	应对可能出现的道路消失的情况
UFLD ^[144]	逐行分类	检测速度快且能应对严重遮挡和极端光照
UFLDv2 ^[145]	混合锚点系统	检测速度快且能应对车道蜿蜒曲折的情况
CondLaneNet ^[146]	条件卷积	应对分叉线、密集线等复杂路况
E2E-LMD ^[149]	逐行分类	无需复杂的后处理工作
IntRA-KD ^[150]	知识蒸馏	处理与环境区分度较低的车道情况
FOLOLane ^[153]	基于关键点	灵活描述车道边线的复杂形状
GANet ^[154]	全局匹配	速度快且能灵活描述车道边线的复杂形状
PINet ^[155]	堆叠沙漏网络	应对车道蜿蜒曲折且数量不定的情况
PolyLaneNet ^[157]	多项式回归	无需复杂的后处理工作
PRNet ^[159]	多项式回归	检测可变量数量的车道
LSTR ^[160]	transformer	检测速度较快
BezierLaneNet ^[162]	贝塞尔曲线	速度快且能应对道路消失的情况

景. LaneAF^[117]的分层深度聚合和迭代深度聚合能够有效聚集语义信息和空间信息,且其所提出的关联字段能够分布在任何前景车道像素的所在位置,突破了固定车道数目的限制. LaneATT^[140]的锚点注意力机制能够利用全局信息定位车道,且其使用的候选线LP组合能够适应现实中的大部分车道类型. UFLDv2^[145]在UFLD^[144]的基础上扩展了原有的锚点系统,优化了模型对垂直车道的检测准确率,使其能够应对半结构化场景中可能出现的丰富车道类型. 而CondLaneNet^[146]的循环实例模块则在面对边线密集与边线交叉的情况时有着较好检测效果. CLRNet^[168]首先基于高级语义特征进行车道检测,对车道边线的所在位置进行粗略估计,再基于互补的细节特征进行精确定位,与此同时,CLRNet利用ROIgather收集全局信息,建立ROI道路特征与图像全局特征之间的联系,以应对车道边线被遮挡以及强光导致的视野模糊等问题.

为了能够详细地了解目前的边线检测方法在半结构化场景下的应用前景,基于引言所提到的半结构化场景的定义和特点,以及本节所讨论的各检测方法的实现原理,对部分方法进行概括总结如表3所示,主要包括每种检测方法的核心思想以及在面对半结构化场景时的应用优势等.

3 边线检测的算法分析

3.1 评价指标

在深度学习领域,混淆矩阵又称为可能性矩阵,用来对分类器分类的准确程度进行衡量,而混淆矩阵的组成则是评价指标的基础,包括真阳性(true positive, TP)、真阴性(true negative, TN)、假阳性(false positive, FP)和假阴性(false negative, FN). 因此,对于二分类问题,其样例总数为(TP+TN+FP+FN).

准确率(Accuracy) $\left(\frac{TP+TN}{TP+FN+FP+TN}\right)$ 、精确率(Precision) $\left(\frac{TP}{TP+FP}\right)$ 以及召回率(Recall) $\left(\frac{TP}{TP+FN}\right)$ 是最常用的对检测性能进行衡量的指标. 通常来讲, Precision 与 Recall 是相互制约的,虽然每种模型都希望同时获得较高的 Precision 和 Recall,但大多时候, Precision 高时 Recall 低, Recall 高时 Precision 低. 因此为了能够综合权衡这两种指标,引入 F-Score,其表达式为

$$F\text{-Score} = (1 + \beta^2) \cdot \left(\frac{\text{Precision} \cdot \text{Recall}}{\beta^2 \cdot \text{Precision} + \text{Recall}}\right). \quad (1)$$

由式(1)可知,当 $\beta = 1$ 时,该指标为 F1-Score,它同时考虑了 Precision 与 Recall. 若希望 Precision 更重要,则使 $\beta < 1$; 若希望 Recall 更重要,则使 $\beta > 1$.

平均精度(average-precision, AP)可以通过 Precision-Recall 曲线与坐标轴之间的面积来表示,而 mAP 则表示多个类别的 AP 的平均值.

交并比(intersection over union, IoU)和 mIoU 也是常用的评价指标,通常用来描述候选区域与原标记区域的交叠率.

3.2 算法性能比较

作为结构化场景的 CULane 数据集包含了 9 种道路状况,是最适合检测性能的数据集之一. 部分边线检测方法在 CULane 数据集上的表现如表 4 所示,评价指标为 F1-Score,每种路况下的最佳和次佳结果分别用粗体和下划线标出. 由于 Cross 类别中的图像没有车道,报告中对应的数值为 FP. 由检测结果可知,CondLaneNet 与 GANet 在面对结构化场景下的边线时展现出较好的检测性能,CondLaneNet 所独有的循环实例模块能够解决具有复杂拓扑结构的车道(例如密集线和分叉)检测问题,使其能够在 CULane 数据集上达到 79.48% 的 F1-Score(较原 SOTA 高 3.2%). 而 GANet 对关键点进行全局回归的方法能够有效利用全局信息,局部信息聚合模块也能够增强相邻关键点之间的相关性,补充局部信息,这使得 GANet 在多个道路场景的检测中均获得了最好成绩.

为了更直观地考察各方法在半结构化场景下的检测性能,给出一份拍摄于重庆市森林越野公园的非城市数据集,包含约 900 张可用图像及其对应的标注信息,并在此数据集上对部分开源的检测模型性能进行评估,结果如表 5 所示. 每种指标的最佳和次佳结果分别用粗体和下划线标出,其中在对 LSTR 的 FPS 进行检测时,将 batchsize 设置为 1. 部分检测模型的可视化结果如图 2 所示. 完整的训练以及测试过程均基于 PyTorch 框架,在 NVIDIA GeForce RTX 2080Ti 算力下完成,采用与 TuSimple 数据集相同的指标计算方式,且每种模型的测试均遵循各自所属方法的实施细节(预处理与后处理等). 该半结构化场景数据集的获取地址为: https://github.com/LiuXingyu0324/Park_Lane_Dataset.

由检测结果可知,UFLD 系列拥有最快的检测速度,其将车道检测从完整图像的像素分割转化为若干行上的分类问题,显著缩减了计算复杂度,使得轻量级版本能够在保持较好性能的情况下达到 350+FPS 的检测速度,而 UFLDv2 在此基础上将行锚扩展为混合锚系统(包括行锚和列锚),增强了模型对垂直车道的定位能力,有助于解决半结构化场景下车道蜿蜒曲

表4 部分边线检测方法在CULane数据集上的表现

method	backbone	normal	crowded	night	no line	shadow	arrow	dazzle	curve	cross	total
E-Net ^[123]	E-Net	88.4	67	61.4	42.9	63.4	81.9	57.4	62.6	2 768	68.8
CondLaneNet ^[146]	ResNet18	92.87	75.79	73.23	52.39	<u>80.01</u>	89.37	70.72	72.4	1 364	78.14
CondLaneNet ^[146]	ResNet34	93.38	77.14	73.92	51.85	79.93	89.89	71.17	73.88	1 387	78.74
CondLaneNet ^[146]	ResNet101	93.47	77.44	74.8	54.13	80.91	<u>90.16</u>	70.93	75.21	1 201	<u>79.48</u>
E2E-LMD ^[149]	ERFNet	91	73.1	67.9	46.6	74.1	85.8	64.5	71.9	2 022	74
FastDraw ^[169]	ResNet50	85.9	63.6	57.8	40.6	59.9	79.4	57	65.2	7 013	—
FOLOLane ^[153]	ERFNet	92.7	77.8	<u>74.5</u>	52.1	79.3	89	75.2	69.4	1 569	78.8
GANet ^[154]	ResNet18	93.24	77.16	72.75	<u>53.59</u>	77.88	89.62	71.24	75.92	1 240	78.79
GANet ^[154]	ResNet34	93.73	<u>77.92</u>	73.67	52.63	79.49	90.37	71.64	<u>76.32</u>	1 368	79.39
GANet ^[154]	ResNet101	<u>93.67</u>	78.66	73.85	53.38	78.32	89.86	<u>71.82</u>	77.37	1 352	79.63
Heatmap-based ^[125]	ERFNet	91.9	72.3	69.4	46.8	74	87.4	67.1	66.4	2 292	74.2
LaneAF ^[117]	E-Net	90.12	72.19	68.67	49.13	76.34	85.13	68.7	64.4	1 934	74.24
LaneAF ^[117]	ERFNet	91.1	73.32	70.9	50.62	75.81	86.86	69.71	65.02	1 844	75.63
LaneAF ^[117]	DLA34	91.8	75.61	73.03	51.38	79.12	86.88	71.78	72.7	1 360	77.41
LaneATT ^[140]	ResNet18	91.17	72.71	68.58	49.13	68.03	87.82	65.82	63.75	1 020	75.13
LaneATT ^[140]	ResNet34	92.14	75.03	70.72	49.39	78.15	88.38	66.47	67.72	1 330	76.68
LaneATT ^[140]	ResNet122	91.74	76.16	70.81	50.46	76.31	86.29	69.47	64.05	1 264	77.02
PRNet ^[159]	ERFNet	92	74.7	70.5	51.7	76	87.8	68.4	70	2 114	76.4
RESA ^[95]	ResNet34	91.9	72.4	69.8	46.3	72	88.1	66.5	68.6	1 896	74.5
RESA ^[95]	ResNet50	92.1	73.1	69.9	47.7	72.8	88.3	69.2	70.3	1 503	75.3
BezierLaneNet ^[162]	ResNet18	90.2	71.6	68.7	45.3	70.9	84.1	62.5	59	<u>996</u>	73.7
BezierLaneNet ^[162]	ResNet34	91.6	73.2	69.9	48.1	76.7	87.2	69.2	62.5	888	75.6
SAD ^[112]	E-Net	90.1	68.8	66	41.6	65.9	84	60.2	65.7	1 998	70.8
SGNet ^[143]	ResNet18	91.42	74.05	70.67	50.16	72.17	87.13	66.89	67.02	1 164	76.12
SGNet ^[143]	ResNet34	92.07	75.41	72.69	50.9	74.31	87.97	67.75	69.65	1 373	77.27
SIM-CycleGAN ^[104]	ERFNet	91.8	71.8	69.4	46.1	76.2	87.8	66.4	67.1	2 346	73.9
UFLD ^[144]	ResNet18	87.7	66	62.1	40.2	62.8	81	58.4	57.9	1 743	68.4
UFLD ^[144]	ResNet34	90.7	70.2	66.7	44.4	69.3	85.7	59.5	69.5	2 037	72.3
UFLDv2 ^[145]	ResNet18	91.8	73.3	70.7	47.6	75.1	87.9	65.3	68.5	2 075	75
UFLDv2 ^[145]	ResNet34	92.5	74.8	70.8	49.2	75.5	88.8	65.5	70.1	1 910	76

表5 部分边线检测方法面对半结构化场景时的表现

method	backbone	F1-Score	Acc	FP	FN	FPS
CondLaneNet ^[146]	ResNet18	74.4	86.4	18.9	31.3	193
CondLaneNet ^[146]	ResNet34	75.3	<u>87.3</u>	21.2	<u>27.8</u>	138
CondLaneNet ^[146]	ResNet101	71.4	86.3	23.6	33.0	47
LaneAF ^[117]	E-Net	67.6	79.7	24.3	38.9	67
LaneAF ^[117]	ERFNet	64.9	77.8	26.8	41.6	74
LaneAF ^[117]	DLA34	78.3	87.9	17.0	25.9	85
LaneATT ^[140]	ResNet18	53.7	67.2	23.7	58.5	205
LaneATT ^[140]	ResNet34	44.5	66.8	40.1	64.6	144
LaneATT ^[140]	ResNet122	53.4	71.4	30.4	56.7	26
UFLD ^[144]	ResNet18	41.6	76.3	64.5	49.8	356
UFLD ^[144]	ResNet34	40.2	76.1	65.5	51.7	220
UFLD ^[144]	ResNet101	35.3	74.9	69.1	58.9	76
UFLDv2 ^[145]	ResNet18	54.9	84.9	44.1	46.1	<u>305</u>
UFLDv2 ^[145]	ResNet34	54.7	84.1	43.1	47.3	173
CLRNet ^[168]	ResNet18	55.0	81.8	42.9	50.5	72
CLRNet ^[168]	ResNet34	54.6	80.7	43.1	51.5	62
CLRNet ^[168]	ResNet101	51.1	76.8	45.1	59.9	38
GANet ^[154]	ResNet18	75.2	83.1	<u>16.3</u>	31.8	76
GANet ^[154]	ResNet34	<u>77.4</u>	84.4	15.3	28.8	65
GANet ^[154]	ResNet101	70.8	87.1	27.0	31.3	30
PolyLaneNet ^[157]	EfficientNet-b0	53.0	83.5	47.3	46.8	73
PolyLaneNet ^[157]	ResNet34	21.0	76.7	79.6	78.3	142
PolyLaneNet ^[157]	ResNet50	30.3	78.4	70.7	68.7	102
LSTR ^[160]	ResNet18	61.2	86.8	40.7	36.7	112
RESA ^[95]	ResNet34	59.2	85.7	35.1	45.6	34
RESA ^[95]	ResNet50	59.3	85.5	34.9	45.6	30

折带来的检测难题,因此在保持高速的情况下提高了检测准确率.如图2第3列所示,UFLD系列在面对弯曲陡峭的山区道路环境时展现出较好的定位能力,有助于移动机器人找到最佳的行车区间.

从检测准确率看,与CULane数据集相比,各算法在半结构化场景下的表现明显较差,主要体现在检测准确率低、误报率(FP)与漏报率(FN)高,表明在脱离标准黄白杆状的车道标记后,各算法对车道点的定位能力下降,在面对路况条件更差的半结构化场景时,容易出现识别错误与无法识别的情况.但LaneAF获得了相对最好的F1-Score(78.3%)以及Accuracy(87.9%),FP和FN也较为可观.其中F1-Score显著优于UFLD与UFLDv2,表明LaneAF错误地检测到车道像素的情况较少,所拥有的多分支结构能够分割独特的车道实例,且其不受预先确定的车道线数量约束的特点,增强了模型对弯曲等具有挑战性行车环境的适应性.但基于分割方法的模型普遍检测速度较慢,例如SCNN^[12]、LaneNet^[115]和RESA.

在CULane数据集测试取得较好成绩的CondLaneNet与GANet在半结构化场景下的检测效



图2 部分边线检测模型在半结构化场景下的可视化结果

果依旧值得肯定.如图2第2列所示,CondLaneNet在面对水坑、道路阴影甚至无边线情况下的优越性能能够很好地应用在半结构化场景中,且CondLaneNet在一定程度上兼顾了速度和精度,轻量级版本下能够达到接近200FPS的检测速度,而GANet则能够灵活描述半结构化场景中频繁出现的弯曲或转弯等复杂的道路状况.

另外,如图2第1列所示,CLRNNet能够利用细节特征辅助边线检测,并充分获取全局信息,使其在面对遮挡与道路阴影的情况时展现出较好性能.

4 问题与挑战

尽管基于深度学习的边线检测方法已经取得了长足的进步,但在面对半结构化场景时仍然存在许多挑战^[17],需要进一步研究:

1) 对于车道线检测,考虑到与普通的语义分割任务不同,车道标记拥有独特的类型(虚线与实线)、形状(细长杆状)和颜色(白色与黄色),因此在神经网络的设计中能否充分考虑到这些独有特性是一个关键问题^[9].

2) 行车过程中常会遇到具有严重遮挡或极端光照等具有挑战性的检测场景,而半结构化道路路面平

整度较差,许多时候存在坑洞、积水以及车道缺失等情况,并且没有规则的、明显可用于区分道路和环境的边界,进一步加大了检测难度,容易导致误识别或者无法识别等问题,给非城市环境下的边线检测带来困难,进而造成安全隐患.

3) 对于视觉感知技术的性能,实时性是一个非常重要的衡量因素,由于视觉感知和机器人的自主运动同步进行,以较差的感知实时性会严重影响机器人相关功能的实现.因此,如何在兼顾边线检测精度的情况下进一步提高算法的检测效率以及降低网络的运算规模使其更适用于车载场景^[9],都是亟待解决的问题.

4) 基于半结构化场景的数据集的缺少同样是制约边线检测发展的重要因素,目前大多数公开数据集均采自城市干道或高速公路等结构化场景,缺乏以半结构化场景为主的数据集.

5 未来展望

综合半结构化场景下移动机器人视觉边线检测技术的研究现状及表现出的问题,对本领域未来的研究方向提出以下展望:

1) 许多现有的边线检测算法已能够很好地定位

通用的车道标志信息,但在面对具有严重遮挡或极端光照等具有挑战性的检测场景时表现不佳.检测方法应当能够更充分地利用局部特征与全局特征,探索车道标志的分布规律,对待检测目标进行更深层次的语义分析,如边线点之间的相互推理和定位等.因此,提出具有鲁棒性的、对道路可能出现的故障或表面变化具有适应性的检测方法是主要的研究方向.

2) 考虑到半结构化场景中常出现的水坑、石块以及树木等非边线标志容易影响模型对边线的定位,可以使用多分支结构,拓展网络对自然物体以及可行驶区域等非边线目标的检测,最大程度地利用可观测到的环境语义信息,进而对边线检测进行指导与辅助.

3) 实时边线检测技术要求兼顾定位准确性和运算速度,即要求模型能够很好地权衡计算复杂度与计算能力,在尽可能保证准确率的情况下缩减运算时间.因此,可以尝试采用对若干行和列进行分类提取的方案代替计算量较大的基于全图的语义分割方案,或者也可以考虑将深度学习融入嵌入式与智能系统的可行性^[9].

4) 充足的具有挑战性场景的数据集既能够用于增强模型对待检测目标的定位能力,也能够优化模型对检测环境变化的适应性,因此提出具有一定规模以及能够充分考虑各种道路状况的半结构化场景数据集是重要的工作方向,而提高检测网络对行车环境的自主学习能力也是优化的有效方式.

参考文献(References)

- [1] Rateke T, Justen K A, Chiarella V F, et al. Passive vision region-based road detection[J]. *ACM Computing Surveys*, 2020, 52(2): 1-34.
- [2] Minar M R, Naher J. Recent advances in deep learning: An overview[J/OL]. 2018, arXiv: 1807.08169.
- [3] Lee C Y, Lee H, Hwang I, et al. Visual perception framework for an intelligent mobile robot[C]. *The 17th International Conference on Ubiquitous Robots*. Kyoto, 2020: 612-616.
- [4] Zhou S Y, Iagnemma K. Self-supervised learning method for unstructured road detection using Fuzzy Support Vector Machines[C]. *IEEE/RSJ International Conference on Intelligent Robots and Systems*. Taipei, 2010: 1183-1189.
- [5] Wang J, Ji Z, Su Y T. Unstructured road detection using hybrid features[C]. *International Conference on Machine Learning and Cybernetics*. Piscataway: IEEE, 2009: 482-486.
- [6] 梁栋, 史忠科. 半结构化道路下智能车辆路径规划与控制算法研究[J]. *交通运输系统工程与信息*, 2011, 11(2): 44-51.
- [7] Liang D, Shi Z K. Path planning and control algorithm for intelligent vehicles under semi-structured road condition[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2011, 11(2): 44-51.
- [8] Kim J, Chung W. Range sensor-based localization of mobile robots in semi-structured environments[C]. *The 10th International Conference on Ubiquitous Robots and Ambient Intelligence*. Jeju, 2013: 219-221.
- [9] 夏庭锴, 杨明, 杨汝清. 基于单目视觉的移动机器人导航算法研究进展[J]. *控制与决策*, 2010, 25(1): 1-7.
- [10] (Xia T K, Yang M, Yang R Q. Progress in monocular vision based mobile robot navigation[J]. *Control and Decision*, 2010, 25(1): 1-7.)
- [11] Zhang Y C, Lu Z Q, Zhang X C, et al. Deep learning in lane marking detection: A survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 5976-5992.
- [12] Wu X W, Sahoo D, Hoi S C H. Recent advances in deep learning for object detection[J]. *Neurocomputing*, 2020, 396: 39-64.
- [13] TuSimple. TuSimple lane detection benchmark[Z]. 2017.
- [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*. New Orleans: AAAI, 2018: 7276-7283.
- [15] Behrendt K, Soussan R. Unsupervised labeled lane markers using maps[C]. *IEEE/CVF International Conference on Computer Vision Workshop*. Seoul, 2020: 832-839.
- [16] Xu H, Wang S J, Cai X Y, et al. CurveLane-NAS: Unifying lane-sensitive architecture search and adaptive point blending[C]. *European Conference on Computer Vision*. Cham: Springer, 2020: 689-704.
- [17] Lee S, Kim J, Yoon J S, et al. VPGNet: Vanishing point guided network for lane and road marking detection and recognition[C]. *IEEE International Conference on Computer Vision*. Venice, 2017: 1965-1973.
- [18] Cheng W S, Luo H, Yang W, et al. Structure-aware network for lane marker extraction with dynamic vision sensor[J/OL]. 2020, arXiv: 2008.06204.
- [19] Aly M. Real time detection of lane markers in urban streets[C]. *IEEE Intelligent Vehicles Symposium*. Eindhoven, 2008: 7-12.
- [20] Zhang Y J, Zhu L, Feng W, et al. VIL-100: A new dataset and A baseline model for video instance lane detection[C]. *IEEE/CVF International Conference on Computer Vision*. Montreal, 2022: 15661-15670.
- [21] Sato T, Chen Q A. Towards driving-oriented metric for lane detection models[J/OL]. 2022, arXiv: 2203.16851.
- [22] Jin D, Park W, Jeong S G, et al. Eigenlanes: Data-driven

- lane descriptors for structurally diverse lanes[J/OL]. 2022, arXiv: 2203.15302.
- [21] Chen L, Sima C H, Li Y, et al. PersFormer: 3D lane detection via perspective transformer and the OpenLane benchmark[J/OL]. 2022, arXiv: 2203.11089.
- [22] Yan F, Nie M, Cai X Y, et al. ONCE-3DLanes: Building monocular 3D lane detection[J/OL]. 2022, arXiv: 2205.00301.
- [23] Yu F, Chen H F, Wang X, et al. BDD100K: A diverse driving dataset for heterogeneous multitask learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 2633-2642.
- [24] Geiger A, Lenz P, Stiller C, et al. Vision meets robotics: The KITTI dataset[J]. International Journal of Robotics Research, 2013, 32(11): 1231-1237.
- [25] Cordts M, Omran M, Ramos S, et al. The cityscapes dataset for semantic urban scene understanding[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 3213-3223.
- [26] Huang X Y, Wang P, Cheng X J, et al. The apolloscape open dataset for autonomous driving and its application[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(10): 2702-2719.
- [27] Brostow G J, Fauqueur J, Cipolla R. Semantic object classes in video: A high-definition ground truth database[J]. Pattern Recognition Letters, 2009, 30(2): 88-97.
- [28] Mapillary. Mapillary research[Z]. 2017.
- [29] Liu X L, Deng Z D, Lu H C, et al. Benchmark for road marking detection: Dataset specification and performance baseline[C]. IEEE 20th International Conference on Intelligent Transportation Systems. Yokohama, 2018: 1-6.
- [30] Wu T, Ranganathan A. A practical system for road marking detection and recognition[C]. IEEE Intelligent Vehicles Symposium. Madrid, 2012: 25-30.
- [31] McCall J C, Trivedi M M. Video-based lane estimation and tracking for driver assistance: Survey, system, and evaluation[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(1): 20-37.
- [32] Butakov V A, Ioannou P. Personalized driver/vehicle lane change models for ADAS[J]. IEEE Transactions on Vehicular Technology, 2014, 64(10): 4422-4431.
- [33] Pan J C, Sun H Y, Xu K C, et al. Lane-attention: Predicting vehicles' moving trajectories by learning their attention over lanes[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas, 2021: 7949-7956.
- [34] Rin V, Nuthong C. Front moving vehicle detection and tracking with Kalman filter[C]. IEEE 4th International Conference on Computer and Communication Systems. Singapore, 2019: 304-310.
- [35] Muhammad K, Ullah A, Lloret J, et al. Deep learning for safe autonomous driving: Current challenges and future directions[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(7): 4316-4336.
- [36] Urmson C, Anhalt J, Bagnell D, et al. Autonomous driving in urban environments: Boss and the urban challenge[J]. Journal of Field Robotics, 2008, 25(8): 425-466.
- [37] Juang L H, Zhang J S. Robust visual line-following navigation system for humanoid robots[J]. Artificial Intelligence Review, 2020, 53(1): 653-670.
- [38] Crayton T J, Meier B M. Autonomous vehicles: Developing a public health research agenda to frame the future of transportation policy[J]. Journal of Transport & Health, 2017, 6: 245-252.
- [39] Wang J, Mei T, Kong B, et al. An approach of lane detection based on inverse perspective mapping[C]. International IEEE Conference on Intelligent Transportation Systems. Qingdao, 2014: 35-38.
- [40] Bertozzi M, Broggi A. GOLD: A parallel real-time stereo vision system for generic obstacle and lane detection[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 1998, 7(1): 62-81.
- [41] Borkar A, Hayes M, Smith M T. Robust lane detection and tracking with ransac and Kalman filter[C]. The 16th IEEE International Conference on Image Processing. Cairo, 2010: 3261-3264.
- [42] Xing Y, Lv C, Wang H J, et al. Dynamic integration and online evaluation of vision-based lane detection algorithms[J]. IET Intelligent Transport Systems, 2019, 13(1): 55-62.
- [43] Yang W J, Yang X H, Wei Y D, et al. Study of the recognition and tracking methods for lane lines based on image edge detections[C]. Proceedings of the International Symposium on Communication Engineering & Computer Science. DOI: 10.2991/cecs-18.2018.33.
- [44] Yang S, Wu J, Shan Y H, et al. A novel vision-based framework for real-time lane detection and tracking[C]. SAE Technical Paper Series. Warrendale, DOI: 10.4271/2019-01-0690.
- [45] Haas R E, Bhattacharjee S, Möller D P F. Advanced driver assistance systems[C]. Smart Technologies. Singapore: Springer, 2020: 345-371.
- [46] da Conceicao M A. Line lane tracker computation using robust feature extraction for autonomous vehicle[J]. Journal Gujarat Research Social, 2019, 21(4): 199-205.
- [47] Han S, Han Y, Hahn H. Vehicle detection method using haar-like feature on real time system[J]. Chemistry, 2009, 15(37): 9521-9529.
- [48] Gopalan R, Hong T, Shneier M, et al. A learning approach

- towards detection and tracking of lane markings[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(3): 1088-1098.
- [49] Kluge K, Lakshmanan S. A deformable-template approach to lane detection[C]. Proceedings of the Intelligent Vehicles'95. Symposium. 2002: 54-59.
- [50] Beauvais M, Kreucher C, Lakshmanan S. Building world models for mobile platforms using heterogeneous sensors fusion and temporal analysis[C]. Proceedings of Conference on Intelligent Transportation Systems. Boston, 2002: 230-235.
- [51] Gonzalez J P, Ozguner U. Lane detection using histogram-based segmentation and decision trees[C]. ITSC2000 IEEE Intelligent Transportation Systems. Dearborn, 2002: 346-351.
- [52] Kim Z. Robust lane detection and tracking in challenging scenarios[J]. IEEE Transactions on Intelligent Transportation Systems, 2008, 9(1): 16-26.
- [53] Mandalia H M, Salvucci M D D. Using support vector machines for lane-change detection[J]. Proceedings of the Human Factors and Ergonomics Society Annual Meeting, 2005, 49(22): 1965-1969.
- [54] Zhou S Y, Jiang Y H, Xi J Q, et al. A novel lane detection based on geometrical model and Gabor filter[C]. IEEE Intelligent Vehicles Symposium. La Jolla, 2010: 59-64.
- [55] Jung C R, Kelber C R. A robust linear-parabolic model for lane following[C]. Proceedings of 17th Brazilian Symposium on Computer Graphics and Image Processing. Curitiba, 2004: 72-79.
- [56] Liu G L, Wörgötter F, Markeli I. Combining statistical hough transform and particle filter for robust lane detection and tracking[C]. IEEE Intelligent Vehicles Symposium. La Jolla, 2010: 993-997.
- [57] Jiang Y, Gao F, Xu G Y. Computer vision-based multiple-lane detection on straight road and in a curve[C]. International Conference on Image Analysis and Signal Processing. Piscataway: IEEE, 2010: 114-117.
- [58] Kang D J, Choi J W, Kweon I S. Finding and tracking road lanes using "line-snakes" [C]. Proceedings of Conference on Intelligent Vehicles. Tokyo, 2002: 189-194.
- [59] Zheng F, Luo S, Song K, et al. Improved lane line detection algorithm based on hough transform[J]. Pattern Recognition and Image Analysis, 2018, 28(2): 254-260.
- [60] Yu B, Jain A K. Lane boundary detection using a multiresolution Hough transform[C]. Proceedings of International Conference on Image Processing. Santa Barbara, 2002: 748-751.
- [61] Madrid N, Hurtik P. Lane departure warning for mobile devices based on a fuzzy representation of images[J]. Fuzzy Sets and Systems, 2016, 291: 144-159.
- [62] Li Y D, Chen L G, Huang H B, et al. Nighttime lane markings recognition based on canny detection and Hough transform[C]. IEEE International Conference on Real-time Computing and Robotics. Angkor Wat, 2016: 411-415.
- [63] Assidiq A A, Khalifa O O, Islam M R, et al. Real time lane detection for autonomous vehicles[C]. International Conference on Computer and Communication Engineering. Kuala Lumpur, 2008: 82-88.
- [64] Zeng D Q, Zeng G G, Kodom P O. Research on recognition technology of vehicle rolling line violation in highway based on visual UAV[C]. Proceedings of the 4th International Conference on Robotics, Control and Automation. Guangzhou, 2019: 198-204.
- [65] Jiang R Y, Klette R, Vaudrey T, et al. New lane model and distance transform for lane detection and tracking[C]. International Conference on Computer Analysis of Images and Patterns. Berlin, Heidelberg: Springer, 2009: 1044-1052.
- [66] Tan H C, Yang Z, Zhu Y, et al. A novel curve lane detection based on Improved River Flow and RANSA[C]. International IEEE Conference on Intelligent Transportation Systems. Qingdao, 2014: 133-138.
- [67] Cao J W, Song C X, Song S X, et al. Lane detection algorithm for intelligent vehicles in complex road conditions and dynamic environments[J]. Sensors: Basel, Switzerland, 2019, 19(14): 3166.
- [68] Wang Y, Teoh E K, Shen D G. Lane detection and tracking using B-Snake[J]. Image and Vision Computing, 2004, 22(4): 269-280.
- [69] Danescu R, Nedeveschi S. Probabilistic lane tracking in difficult road scenarios using stereovision[J]. IEEE Transactions on Intelligent Transportation Systems, 2009, 10(2): 272-282.
- [70] López A, Serrat J, Cañero C, et al. Robust lane markings detection and road geometry computation[J]. International Journal of Automotive Technology, 2010, 11(3): 395-407.
- [71] He Y H, Hong W, Zhang B. Color based road detection in urban traffic scenes[C]. Proceedings of the 2003 IEEE International Conference on Intelligent Transportation Systems. Shanghai, 2004: 730-735.
- [72] Sun T Y, Tsai S J, Chan V. HSI color model based lane-marking detection[C]. IEEE Intelligent Transportation Systems Conference. Toronto, 2006: 1168-1172.
- [73] Chiu K Y, Lin S F. Lane detection using color-based segmentation[C]. IEEE Proceedings Intelligent Vehicles Symposium. Las Vegas, 2005: 706-711.
- [74] Wang Y, Shen D G, Teoh E K. Lane detection using spline model[J]. Pattern Recognition Letters, 2000, 21(8): 677-689.
- [75] Li Z Q, Ma H M, Liu Z Y. Road lane detection with

- Gabor filters[C]. International Conference on Information System and Artificial Intelligence. Hong Kong, 2017: 436-440.
- [76] Wu P C, Chang C, Lin C H. Lane-mark extraction for automobiles under complex conditions[J]. Pattern Recognition, 2014, 47(8): 2756-2767.
- [77] Veit T, Tarel J P, Nicolle P, et al. Evaluation of road marking feature extraction[C]. The 11th International IEEE Conference on Intelligent Transportation Systems. Beijing, 2008: 174-181.
- [78] Borkar A, Hayes M, Smith M T. A novel lane detection system with efficient ground truth generation[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(1): 365-374.
- [79] Deusch H, Wiest J, Reuter S, et al. A random finite set approach to multiple lane detection[C]. The 15th International IEEE Conference on Intelligent Transportation Systems. Anchorage, 2012: 270-275.
- [80] Jung H, Min J, Kim J. An efficient lane detection algorithm for lane departure detection[C]. IEEE Intelligent Vehicles Symposium. Gold Coast, 2013: 976-981.
- [81] McCall J C, Trivedi M M. An integrated, robust approach to lane marking detection and lane tracking[C]. IEEE Intelligent Vehicles Symposium. Parma, 2004: 533-537.
- [82] Jung S, Youn J, Sull S. Efficient lane detection based on spatiotemporal images[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(1): 289-295.
- [83] Hur J, Kang S N, Seo S W. Multi-lane detection in urban driving environments using conditional random fields[C]. 2013 IEEE Intelligent Vehicles Symposium. Gold Coast, 2013: 1297-1302.
- [84] Son J, Yoo H, Kim S, et al. Real-time illumination invariant lane detection for lane departure warning system[J]. Expert Systems with Applications, 2015, 42(4): 1816-1824.
- [85] Satzoda R K, Trivedi M M. Vision-based lane analysis: Exploration of issues and approaches for embedded realization[C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops. Portland, 2013: 604-609.
- [86] Yenikaya S, Yenikaya G, Düven E. Keeping the vehicle on the road: A survey on on-road lane detection systems[J]. ACM Computing Surveys, 2013, 46(1): 1-43.
- [87] Hillel A B, Lerner R, Levi D, et al. Recent progress in road and lane detection: A survey[J]. Machine Vision and Applications, 2014, 25(3): 727-745.
- [88] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [89] Everingham M, Van Gool L, Williams C K I, et al. The pascal visual object classes (VOC) challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303-338.
- [90] Huval B, Wang T, Tandon S, et al. An empirical evaluation of deep learning on highway driving[J/OL]. 2015, arXiv: 1504.01716.
- [91] Kim J, Lee M. Robust lane detection based on convolutional neural network and random sample consensus[C]. International Conference on Neural Information Processing. Cham: Springer, 2014: 454-461.
- [92] Cirean D C, Giusti A, Gambardella L M, et al. Mitosis detection in breast cancer histology images with deep neural networks[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Heidelberg: Springer, 2013: 411-418.
- [93] Liang D, Guo Y C, Zhang S K, et al. LineNet: A zoomable CNN for crowdsourced high definition maps modeling in urban environments[J/OL]. 2018, arXiv: 1807.05696.
- [94] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 6230-6239.
- [95] Zheng T, Fang H, Zhang Y, et al. RESA: Recurrent feature-shift aggregator for lane detection[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(4): 3547-3554.
- [96] Fan R C, Wang X R, Hou Q B, et al. SpinNet: Spinning convolutional network for lane boundary detection[J]. Computational Visual Media, 2019, 5(4): 417-428.
- [97] Long J, Shelhamer E E, Darrell T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, 2015: 3431-3440.
- [98] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [99] Wang Z, Ren W Q, Qiu Q. LaneNet: Real-time lane detection networks for autonomous driving[J/OL]. 2018, arXiv: 1807.01726.
- [100] Chen P R, Lo S Y, Hang H M, et al. Efficient road lane marking detection with deep learning[C]. Proceedings of the IEEE International Conference on Digital Signal Processing. Shanghai, 2018: 1-5.
- [101] Ghafoorian M, Nugteren C, Baka N, et al. EL-GAN: Embedding loss driven generative adversarial networks for lane detection[C]. Computer Vision—ECCV 2018 Workshops. Munich, 2018: 256-272.
- [102] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]. Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, 2014: 2672-2680.

- [103] Zhang Y C, Lu Z Q, Ma D D, et al. Ripple-GAN: Lane line detection with ripple lane line detection network and Wasserstein GAN[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(3): 1532-1542.
- [104] Liu T, Chen Z W, Yang Y, et al. Lane detection in low-light conditions using an efficient data enhancement: Light conditions style transfer[C]. *IEEE Intelligent Vehicles Symposium*. Las Vegas, 2021: 1394-1399.
- [105] Huang G, Liu Z, van Der Maaten L, et al. Densely connected convolutional networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, 2017: 2261-2269.
- [106] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [107] Yin R C, Cheng Y, Wu H P, et al. FusionLane: Multi-sensor fusion for lane marking semantic segmentation using deep neural networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(2): 1543-1553.
- [108] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM Network: A machine learning approach for precipitation nowcasting[C]. *Proceedings of the 28th International Conference on Neural Information Processing Systems*. Montreal, 2015: 802-810.
- [109] Zou Q, Jiang H W, Dai Q Y, et al. Robust lane detection from continuous driving scenes using deep neural networks[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(1): 41-54.
- [110] Zhang J Y, Deng T, Yan F, et al. Lane detection model based on spatio-temporal network with double convolutional gated recurrent units[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 6666-6678.
- [111] Li J, Mei X, Prokhorov D, et al. Deep neural network for structural prediction and lane detection in traffic scene[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(3): 690-703.
- [112] Hou Y N, Ma Z, Liu C X, et al. Learning lightweight lane detection CNNs by self attention distillation[C]. *IEEE/CVF International Conference on Computer Vision*. Seoul, 2020: 1013-1021.
- [113] Xu X M, Yu T F, Hu X W, et al. SALMNet: A structure-aware lane marking detection network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(8): 4986-4997.
- [114] Xiao D G, Yang X F, Li J F, et al. Attention deep neural network for lane marking detection[J]. *Knowledge-Based Systems*, 2020, 194: 105584.
- [115] Neven D, De Brabandere B, Georgoulis S, et al. Towards end-to-end lane detection: An instance segmentation approach[C]. *IEEE Intelligent Vehicles Symposium*. Changshu, 2018: 286-291.
- [116] Hsu Y C, Xu Z, Kira Z, et al. Learning to cluster for proposal-free instance segmentation[C]. *International Joint Conference on Neural Networks*. Rio de Janeiro, 2018: 1-8.
- [117] Abualsaud H, Liu S A, Lu D, et al. LaneAF: Robust multi-lane detection with affinity fields[J/OL]. 2021, arXiv: 2103.12040.
- [118] Yu F, Wang D Q, Shelhamer E, et al. Deep layer aggregation[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 2403-2412.
- [119] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, 2017: 936-944.
- [120] Chng Z M, Lew J M H, Lee J A. RONELD: Robust neural network output enhancement for active lane detection[C]. *The 25th International Conference on Pattern Recognition*. Milan, 2021: 6842-6849.
- [121] Lu S, Luo Z J, Gao F, et al. A fast and robust lane detection method based on semantic segmentation and optical flow estimation[J]. *Sensors: Basel, Switzerland*, 2021, 21(2): 400.
- [122] Homayounfar N, Liang J, Ma W C, et al. DAGMapper: Learning to map by discovering lane topology[C]. *IEEE/CVF International Conference on Computer Vision*. Seoul, 2020: 2911-2920.
- [123] Hou Y N. Agnostic lane detection[J/OL]. 2019, arXiv: 1905.03704.
- [124] Chen Z, Chen Z J. RBNet: A deep neural network for unified road and road boundary detection[C]. *International Conference on Neural Information Processing*. Cham: Springer, 2017: 677-687.
- [125] Liu Y B, Zeng M, Meng Q H. Heatmap-based vanishing point boosts lane detection[J/OL]. 2020, arXiv: 2007.15602.
- [126] Pizzati F, Allodi M, Barrera A, et al. Lane detection and classification using cascaded CNNs[C]. *International Conference on Computer Aided Systems Theory*. Cham: Springer, 2020: 95-103.
- [127] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, 2016: 770-778.
- [128] Paszke A, Chaurasia A, Kim S, et al. ENet: A deep neural network architecture for real-time semantic segmentation[J/OL]. 2016, arXiv: 1606.02147.
- [129] Romera E, Álvarez J M, Bergasa L M, et al. ERFNet: Efficient residual factorized ConvNet for real-time semantic segmentation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(1): 263-272.

- [130] Pizzati F, García F. Enhanced free space detection in multiple lanes based on single CNN with scene identification[C]. IEEE Intelligent Vehicles Symposium. Paris, 2019: 2536-2541.
- [131] Lo S Y, Hang H M, Chan S W, et al. Efficient dense modules of asymmetric convolution for real-time semantic segmentation[C]. Proceedings of the ACM Multimedia Asia. Beijing, 2019: 1-6.
- [132] Lo S Y, Hang H M, Chan S W, et al. Multi-class lane semantic segmentation using efficient convolutional networks[C]. IEEE 21st International Workshop on Multimedia Signal Processing. Kuala Lumpur, 2019: 1-6.
- [133] Lin G S, Milan A, Shen C H, et al. RefineNet: Multi-path refinement networks for high-resolution semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 5168-5177.
- [134] Briot A, Viswanath P, Yogamani S. Analysis of efficient CNN design techniques for semantic segmentation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City, 2018: 77609.
- [135] Ren S Q, He K M, 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.
- [136] Gelernter Y T, Wang X, Chen W G, et al. Lane marking detection via deep convolutional neural network[J]. Neurocomputing, 2018, 280: 46-55.
- [137] Li X, Li J, Hu X L, et al. Line-CNN: End-to-end traffic line detection with line proposal unit[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(1): 248-258.
- [138] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 779-788.
- [139] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot MultiBox detector[C]. Computer Vision—ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [140] Tabelini L, Berriel R, Paixão T M, et al. Keep your eyes on the lane: Real-time attention-guided lane detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 294-302.
- [141] Chen Z P, Liu Q F, Lian C F. PointLaneNet: Efficient end-to-end CNNs for accurate real-time lane detection[C]. IEEE Intelligent Vehicles Symposium. Paris, 2019: 2563-2568.
- [142] Zoph B, Vasudevan V, Shlens J, et al. Learning transferable architectures for scalable image recognition[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 8697-8710.
- [143] Su J M, Chen C, Zhang K, et al. Structure guided lane detection[C]. Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. Montreal, 2021: 997-1003.
- [144] Qin Z Q, Wang H Y, Li X. Ultra fast structure-aware deep lane detection[C]. European Conference on Computer Vision. Cham: Springer, 2020: 276-291.
- [145] Qin Z Q, Zhang P Y, Li X. Ultra fast deep lane detection with hybrid anchor driven ordinal classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022(99): 1-14.
- [146] Liu L Z, Chen X H, Zhu S Y, et al. CondLaneNet: A top-to-down lane detection framework based on conditional convolution[C]. IEEE/CVF International Conference on Computer Vision. Montreal, 2022: 3753-3762.
- [147] Tian Z, Shen C H, Chen H. Conditional convolutions for instance segmentation[C]. European Conference on Computer Vision. Cham: Springer, 2020: 282-298.
- [148] Wang X L, Zhang R F, Kong T, et al. SOLOv2: Dynamic and fast instance segmentation[C]. Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, 2020: 17721-17732.
- [149] Yoo S, Lee H S, Myeong H, et al. End-to-end lane marker detection via row-wise classification[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle, 2020: 4335-4343.
- [150] Hou Y N, Ma Z, Liu C X, et al. Inter-region affinity distillation for road marking segmentation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 12483-12492.
- [151] Papandreou G, Zhu T, Chen L C, et al. PersonLab: Person pose estimation and instance segmentation with a bottom-up, part-based, geometric embedding model[C]. European Conference on Computer Vision. Cham: Springer, 2018: 282-299.
- [152] Cao Z, Hidalgo G, Simon T, et al. OpenPose: Realtime multi-person 2D pose estimation using part affinity fields[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(1): 172-186.
- [153] Qu Z, Jin H, Zhou Y, et al. Focus on local: Detecting lane marker from bottom up via key point[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 14117-14125.
- [154] Wang J S, Ma Y C, Huang S F, et al. A keypoint-based global association network for lane detection[J/OL]. 2022, arXiv: 2204.07335.
- [155] Ko Y, Lee Y, Azam S, et al. Key points estimation and point instance segmentation approach for lane detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 8949-8958.
- [156] Newell A, Yang K Y, Deng J. Stacked hourglass networks for human pose estimation[C]. European Conference on

- Computer Vision. Cham: Springer, 2016: 483-499.
- [157] Tabelini L, Berriel R, Paixao T M, et al. PolyLaneNet: Lane estimation via deep polynomial regression[C]. Proceedings of the International Conference on Pattern Recognition. Milan, 2021: 6150-6156.
- [158] van Gansbeke W, de Brabandere B, Neven D, et al. End-to-end lane detection through differentiable least-squares fitting[C]. IEEE/CVF International Conference on Computer Vision Workshop. Seoul, 2020: 905-913.
- [159] Wang B K, Wang Z L, Zhang Y X. Polynomial regression network for variable-number lane detection[C]. European Conference on Computer Vision. Cham: Springer, 2020: 719-734.
- [160] Liu R J, Yuan Z J, Liu T, et al. End-to-end lane shape prediction with transformers[C]. IEEE Winter Conference on Applications of Computer Vision. Waikoloa, 2021: 3693-3701.
- [161] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J/OL]. 2017, arXiv: 1706.03762.
- [162] Feng Z Y, Guo S H, Tan X, et al. Rethinking efficient lane detection via curve modeling[J/OL]. 2022, arXiv: 2203.02431.
- [163] Garnett N, Cohen R, Pe'er T, et al. 3D-LaneNet: End-to-end 3D multiple lane detection[C]. IEEE/CVF International Conference on Computer Vision. Seoul, 2020: 2921-2930.
- [164] Efrat N, Bluvstein M, Oron S, et al. 3D-LaneNet+: Anchor free lane detection using a semi-local representation[J/OL]. 2020, arXiv: 2011.01535.
- [165] Guo Y L, Chen G, Zhao P T, et al. Gen-LaneNet: A generalized and scalable approach for 3D lane detection[C]. European Conference on Computer Vision. Cham: Springer, 2020: 666-681.
- [166] Jin Y J, Ren X X, Chen F X, et al. Robust monocular 3D lane detection with dual attention[C]. IEEE International Conference on Image Processing. Anchorage, 2021: 3348-3352.
- [167] Efrat N, Bluvstein M, Garnett N, et al. Semi-local 3D lane detection and uncertainty estimation[J/OL]. 2020, arXiv: 2003.05257.
- [168] Zheng T, Huang Y F, Liu Y, et al. CLRNet: Cross layer refinement network for lane detection[J/OL]. 2022, arXiv: 2203.10350.
- [169] Philion J. FastDraw: Addressing the long tail of lane detection by adapting a sequential prediction network[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2020: 11574-11583.
- [170] Chougule S, Koznek N, Ismail A, et al. Reliable multilane detection and classification by utilizing CNN as a regression network[C]. European Conference on Computer Vision. Cham: Springer, 2019: 740-752.
- [171] Yurtsever E, Lambert J, Carballo A, et al. A survey of autonomous driving: Common practices and emerging technologies[J]. IEEE Access, 2020, 8: 58443-58469.

作者简介

苏晓杰(1985—),男,教授,博士,从事智能控制及工业应用、优化控制及分布式控制、智能机器人及无人控制系统应用等研究, E-mail: suxiaojie@cqu.edu.cn;

刘星雨(1999—),男,硕士生,从事计算机视觉、深度学习的目标检测等研究, E-mail: liuxingyu@cqu.edu.cn;

李睿(1990—),男,讲师,博士,从事机器人感知与机器人操作的研究, E-mail: rui.li@cqu.edu.cn;

谭威(1981—),男,硕士生,从事计算机视觉、深度学习等研究, E-mail: WeiT@cqu.edu.cn;

郜深阵(1996—),男,硕士生,从事计算机视觉、目标检测等研究, E-mail: shenzhengao@cqu.edu.cn.

科研团队简介

重庆大学自动化学院机器人与智能系统研究所团队依托机械传动国家重点实验室、复杂系统安全与自主控制教育部重点实验室等平台,在机器人机构设计、导航规划、感知识别、智能控制等领域开展了深入研究,在特种机器人系统集成与控制方面具有深厚积累.承担参与国家科技部重点研发计划、国家自然科学基金国际合作项目、军委科技委重大项目等科研项目20余项.在相关领域获重庆市自然科学奖一等奖1项、黑龙江省自然科学一等奖2项,发表相关论文200余篇,申请国家发明专利20余项.

团队包括中组部青年拔尖人才、高被引科学家、重庆市青年拔尖人才、重庆大学“百人计划”教授等高层次人才.目前实验室拥有固定教学与科学研究人员14人,其中教授/研究员3人,副教授2人,弘深博士后6人,高级工程师3人,在读硕博研究生70余人.团队针对机器人与智能系统的重大科学需求、未来人工智能军民融合的重大战略需求和智能制造的重大社会需求,围绕“自主与感知”“集群与协同”等关键科学问题,从机器人自主操作与仿人交互、动态目标检测、多体与协同等研究方向展开科研攻关;已建设面向军民融合的机器人操作平台、无人系统先进技术研发平台,并与军委科技委、总装、兵装、重庆铁马、贵州天马、重庆长安、重庆嘉陵等单位保持深度合作,在机器人与自主智能无人系统领域取得了一批原始创新性研究成果.实验室着力推动智能制造、智慧医疗、智慧安防、智能交通、智慧城市等领域的产业变革,力争成为具有国际影响力的机器人与智能系统研究团队.