

车道线深度学习检测技术在辅助驾驶中的应用研究

王 敬¹
WANG Jing

摘 要

复杂环境下道路路面情况千变万化,采集的初始车道线图像受到阴影、破损、污渍等因素干扰,难以区分前景与背景,车道线形状及曲线特性提取效果不佳,无法准确进行识别与跟踪,进而影响其辅助驾驶效果。为此,文章提出车道线深度学习检测技术在辅助驾驶中的应用研究。部署传感器,采集包含车道线的道路图像数据并作出标注;为有效区分图像前景与背景,构建深度学习模型,通过模型中的卷积模块来提取车道线的细长形状和曲线特性,识别并跟踪车道线;将检测到的车道线信息应用于辅助驾驶路径规划中,以为车辆提供准确的行驶指导。实验结果表明,该项技术应用后,在阴影干扰和车道线位置发生较大变化的情况下,车辆仍能准确检测车道线的位置,且在各种复杂环境下的车道偏离辅助效率均较高,能够更准确地识别车道线,为车辆提供及时有效的车道偏离辅助。

关键词

车道线;深度学习;智能检测;辅助驾驶;路径规划;安全性

doi: 10.3969/j.issn.1672-9528.2025.07.041

0 引言

在复杂的道路环境中,车道线往往受到外界环境等因素干扰,导致初始采集的图像质量下降,前景与背景难以区分,进而影响车道线识别的准确性。良好的车道线识别对车辆辅助驾驶至关重要,车辆在复杂环境下需要能够准确地识别车道线,以便更好地规划行驶路线、保持车速稳定,并降低交通事故的发生率^[1]。因此,开展车道线深度学习检测技术在辅助驾驶中的应用研究具有重要意义。通过深入研究这一技术,可以提高车道线识别的准确性和鲁棒性,为辅助驾驶系统提供更加可靠的支持,进而推动自动驾驶技术的进一步发展。

近年来,众多学者针对车道线检测技术开展研究,并已经取得一定研究成果。如文献[2]提出的检测方法通过结合SAGAN生成图像扩充数据集与ResNeXt网络,实现车道线的识别。该方法由于未对图像初始采集进行设计,在极端天气或非结构化道路等场景下,图像采集效果不佳,进而直接影响后期检测结果的稳定性与准确性,无法为辅助驾驶提供稳定技术支持。文献[3]提出的检测方法通过空洞卷积和融合注意力机制提取多尺度特征实现车道线检测目标。该方法同样未对复杂道路环境对初始图像采集造成的干扰进行处理,导致其在复杂场景下存在边缘细节识别不敏感的问题,

难以良好辅助驾驶。

在该背景下,提出车道线深度学习检测技术在辅助驾驶中的应用研究。希望可通过本次研究,提高车道线检测的准确性和实时性,以为智能辅助驾驶系统的发展提供技术支持。

1 车道线图像采集

为确保图像采集的精确性和清晰度,本次选择适合道路环境的HIKVISION 22V2-IA 4MM高清摄像头作为图像采集传感器,其规格参数如表1所示。

表1 图像采集传感器规格参数

序号	规格	参数
1	分辨率	1 920 px×1 080 px (全高清)
2	帧率	30 帧/s, 支持高速图像捕捉
3	视角	水平 120°, 垂直 90°, 宽广视野
4	光圈	自动/手动调节, F1.6 大光圈
5	传感器类型	CMOS, 低噪点, 高灵敏度
6	动态范围	120 dB, 适应高对比度场景

为确保图像采集传感器能够满足车道线检测的需求。将其安装在车辆的前部或顶部,以确保摄像头能够清晰地捕捉到前方的道路图像^[4]。对摄像头进行校准,包括焦距调整、图像畸变校正等,以确保采集到的图像质量符合后续处理的要求。

在数据采集阶段,规划采集路线,其涵盖多种道路类型和复杂场景,道路类型包括直线道路、曲线道路、交叉路口,复杂场景包括如夜间、雨天、雾天等,以丰富数据集并提升深度学习模型的泛化能力。利用车载存储设备1 TB SSD硬盘将采集到的图像数据进行安全存储,并建立文件夹结构,

1. 厦门工学院机械电气与信息工程学院 福建厦门 361021
[基金项目] 2023 年度福建省中青年教师教育科研项目(科技类)“基于深度学习的车道线检测方法在辅助驾驶中的应用”(JAT231161)

按照日期、地点、天气条件对其进行命名，以便于后续的数据管理^[5]。

在完成初始数据采集后，本次利用 LabelImg 标注工具，对收集的图像数据进行手动标注，以标记出车道线的位置。标注结果包括车道线的像素级掩码、关键点坐标^[6]。将标注好的图像数据和标注结果存储在数据库中，并每周一次进行备份，确保数据的完整性和可用性。

2 构建车道线检测深度学习模型

复杂道路车道线图像采集及标注处理可确保数据的多样性和准确性，使得模型训练过程更加高效和可靠。并以此为基础，基于深度学习理论构建车道线深度检测模型，以实现道路车道线识别^[7]。根据采集的图像设计深度学习模型的输入层，确保其能够接收并处理此类图像数据。为从图像中提取出车道线的特征信息，采用了卷积神经网络（convolutional neural network, CNN）模块。CNN 通过多层卷积操作，能够学习到图像中的局部特征^[8]。本次设计使用大小为 3×3 的卷积核，步长为 1，填充为 1，以保持特征图的空间尺寸不变，其卷积操作公式为：

$$Y = W \cdot X + b \quad (1)$$

式中： X 是输入特征图； W 是卷积核的权重； b 是偏置项； Y 是输出特征图。

针对车道线的细长形状与曲线特性，引入特定的卷积核和池化策略：即使用垂直方向的卷积核来增强对车道线纵向特征的提取能力，同时使用最大池化操作来减少特征图的尺寸，提高计算效率^[9]。池化操作的公式为：

$$Y' = \max(Y_{i,j}) \quad (2)$$

式中： i, j 表示特征图上的位置索引。最大池化操作在给定区域内选择最大值作为输出。

最后，设计了一个基于分割的车道线检测模块。该模块使用全卷积网络（FCN）结构，能够输出与输入图像大小相同的特征图，每个像素点对应一个车道线类别的预测^[10]。分割任务的公式可以表示为：

$$Y'' = \text{softmax}(W \cdot Y' + b) \quad (3)$$

经过 softmax 函数处理后，每个像素点上的值表示该点属于不同车道线类别的概率。

根据标注数据的类型和检测任务的需求，设计输出层。对于像素级掩码输出，输出层的大小与输入图像相同，每个像素点表示该点是否属于车道线；对于关键点坐标输出，输出层的大小为关键点数量的两倍，分别表示每个关键点的横纵坐标。将已标注的图像数据按比例分为训练集（占比 80%）、验证集（占比 10%）及测试集（占比 10%），并准备了相应的数据加载器来读取数据。在利用训练集对模型实施训练的过程中，采取了反向传播策略来动态调整模型的权

重参数。反向传播的公式为：

$$\Delta W = -\eta \cdot \frac{\partial L}{\partial W} \quad (4)$$

$$\Delta b = -\eta \cdot \frac{\partial L}{\partial b} \quad (5)$$

式中： η 是学习率； L 是损失函数； ΔW 和 Δb 分别是权重和偏置项的更新量。

综上，不断更新模型权重 W 、 b ，完成车道线检测模型训练，将训练好的模型保存到磁盘中，以便后续进行推理和部署。

3 基于车道线检测的辅助驾驶路径规划

完成车道线检测模型构建可实现高精度的车道线识别，使得自动驾驶系统能够准确感知道路环境。接下来，从上述构建的深度学习模型输出中解析出车道线的位置信息。为将这些检测结果转化为可用于路径规划的可靠信息，进行一系列后处理，具体设计如下：

首先，对于车道线图像 Y'' 进行拟合处理。本文采用了二次多项式拟合方法，该方法能够很好地描述车道线的弯曲特性。设车道线上的一组关键点坐标为 (x_i, y_i) ，则二次多项式拟合的公式为：

$$y = ax^2 + bx + c \quad (6)$$

式中： a 、 b 和 c 为待拟合的多项式系数。通过最小二乘法，求解出这些系数，从而得到车道线的拟合曲线。

然后，为过滤掉检测结果中的噪声点，采用了基于距离阈值的滤波方法。设车道线上某一点到拟合曲线的垂直距离为 d ，若 d 大于预设的阈值 T ，则将该点视为噪声点并予以剔除。

最后，在车道线的连接和延伸方面，采用了基于直线段连接的方法。当检测到断裂的车道线时，会在断裂处插入直线段，以确保车道线的连续性。通过后处理，以提高检测的准确性和鲁棒性。

经过上述后处理步骤后，得到了更加准确和鲁棒的车道线信息。接下来，利用 Dijkstra 路径规划算法，根据预处理后的车道线信息，规划生成车辆的行驶路径。Dijkstra 算法是一种经典的图搜索算法，其能够在加权图中找到从起点到终点的最短路径。在路径规划任务中，将车道线视为图中的节点，节点之间的距离可以根据车道线的曲率得出。Dijkstra 算法的公式可以表示为：

$$D(v) = \min_{u \in V-S} \{yD(u) + c(u, v)\} \quad (7)$$

式中： $D(v)$ 表示从起点到节点 v 的最短路径长度； V 表示节点集合； S 表示已找到最短路径的节点集合； $c(u, v)$ 表示从节点 u 到节点 v 的代价。

根据路径规划信息，生成相应的控制指令，如转向角度、油门踏板位置等，并将这些指令发送给车辆的辅助控制系统，

即可帮助车辆实时监控车道线检测 results 和路径规划信息的变化，并根据需要进行调整和优化，以确保车辆能够始终沿着正确的车道安全、舒适地行驶。

4 实验分析

4.1 实验准备

为评估所开发的车道线深度学习检测技术的效果与适用范围，本次选取了 CULane 数据集进行实验验证。该数据集因其丰富的多样性在车道线检测技术性能评估中占据重要地位，内含超过 133 000 幅图像，广泛覆盖了从都市到乡村、高速公路、隧道，以及夜间、雨天等多种复杂多变的驾驶情境，从而确保了实验验证的全面性和深度。图像的帧率为 24 帧/s，分辨率为 1 920 px×1 080 px，与车载摄像头的配置相匹配。针对深度学习算法，设定配置参数，如表 2 所示。

表 2 深度学习算法配置参数

序号	配置项	参数值
1	初始学习率	0.001
2	权重衰减	0.000 5
3	Batch Size	32
4	Epoch	50

鉴于车辆驾驶环境的复杂多变，从 CULane 数据集中随机抽取了一组涵盖不同场景的车道线图像，用于实验测试，图像示例如图 1 所示。



图 1 车道线原始图像

在此基础上，应用上文设计的车道线深度学习检测技术，对这些图像进行了实验测试。

4.2 实验结果分析

为全面且客观地验证本文所提出的车道线检测技术的优越性，选取图 1 所示的相同测试图像集，并将其与两种传统的车道线检测技术——即文献 [2] 与文献 [3] 中所述技术进行对比分析。

车道线检测效果的直观对比展示在如图 2 所示。在面对车道线位置的变化以及阴影对车道线的干扰时，本文提出的车道线深度学习检测技术展现出了出色的适应性。该技术不仅准确地捕捉到了车道线的位置，而且在阴影干扰和车道线位置发生较大变化的情况下，检测效果依然稳健，实现了更高的准确性和更强的适应性。相比之下，虽然文献 [2] 和文献 [3] 的技术在正常道路上的检测表现优异，但在面对阴影干扰或车道线位置变化较大的复杂场景时，其检测准确性明显较低。这主要是因为这两种传统技术在对车道特征信息的

提取上存在不足。




图 2 不同场景下车道线检测效果对比

为进一步量化本文技术的优势，此次实验还以车道偏离辅助效率为评估指标，评估各技术在复杂环境下的性能表现。选择具备车道偏离辅助功能的测试车辆，并确保其车道偏离辅助系统正常工作。安装摄像头、数据采集系统，作为测试设备，用于记录车辆行驶过程中的车道线检测情况和车道偏离辅助效果。设定夜晚、雨天、雪天、隧道、乡村 5 种不同的测试场景，确保每种场景下的道路条件、光照条件等符合实验要求。将测试车辆驶入设定的测试场景，开始实验。开启车道偏离辅助功能，记录车辆行驶过程中的车道线检测情况和车道偏离辅助效果，结果如图 3 所示。




图 3 车道偏离辅助效率对比结果

从图 3 的对比结果中，可以得出以下结论：在各类驾驶场景下，本文提出的车道线深度学习检测技术应用后，在各种复杂环境下的车道偏离辅助效率均较高，能够更准确地识别车道线，为车辆提供及时有效的车道偏离辅助，车道偏离辅助效率均明显高于文献 [2] 和文献 [3] 中的技术。特别是在夜晚、雨天、雪天等复杂环境下，本文技术的优势更为显著，这进一步证明了其在处理复杂场景时的优越性能。

5 结语

车道线深度学习检测技术在辅助驾驶中的应用研究，不仅标志着自动驾驶技术迈向了更加智能化、精细化的新阶段，

(下转第 179 页)

将训练好的 YOLOv5 茶叶病害识别模型部署在移动设备应用系统上, 建立基于 Android 平台的实时检测系统客户端, 使用该 Python 集成开发工具 PyCharm 用于开发 Android 的 HTTP 请求的服务端, 提供单幅图像检测时的云服务器端响应服务。具体工作流程用户在前端上传茶叶病害图像, 系统先对上传的图像进行预处理, 然后将预处理的病害图像上传至云端, 利用训练好的模型进行识别, 最后将识别结果传回至前端页面反馈给用户。系统包括用户登录、数据采集、病害识别检测和结果展示等功能, 能够满足茶叶种植户的实用需求。该系统可推广应用于其他农作物病害识别领域, 为农业生产提供更广泛的技术支持。

参考文献:

[1] 张莉, 杨明辉, 孙嘉成. 基于注意力机制和迁移学习的小样本茶叶病害识别 [J]. 中国农机化学报, 2024, 45(10): 262-268.

[2] 姜晟, 曹亚芃, 刘梓伊, 等. 基于改进 Faster RCNN 的茶叶部病害识别 [J]. 华中农业大学学报, 2024, 43(5): 41-50.

[3] 李博. 基于边缘智能的茶叶病害识别 [D]. 合肥: 安徽农业大学, 2021.

[4] 徐杰. 基于 ResNet 的茶叶病害识别系统设计与实现 [J]. 电子技术与软件工程, 2022,(12):167-170.

(上接第 175 页)

也为提升道路安全、优化驾驶体验开辟了全新的路径。通过深度学习模型的强大特征提取与模式识别能力, 车道线检测技术得以在复杂多变的交通环境中准确识别车道边界, 为车辆提供可靠的行驶引导。本次基于构建的深度学习模型通过学习大量标注好的车道线图像数据, 逐步掌握车道线的形态规律。结合后处理算法, 进一步提升了车道线信息的精确性与连续性, 为路径规划与控制策略的制定奠定了坚实基础。车道线深度学习检测技术与辅助驾驶系统的深度融合, 不仅优化了车辆的行驶轨迹, 还促进了智能驾驶辅助功能如车道保持、自动转向等的智能化升级。这些功能的实现, 不仅减轻了驾驶员的操控负担, 更为未来完全自动驾驶的实现奠定了技术基础。

参考文献:

[1] 潘玉恒, 刘泽帅, 鲁维佳, 等. 基于生成式对抗网络与 Res-NeXt 的车道线检测算法 [J]. 公路交通科技, 2024, 41 (12): 39-47.

[2] 李沐原, 张兰春, 张博源. 基于多尺度空洞融合注意力的车道线检测算法 [J]. 电子测量技术, 2024, 47 (23): 84-92.

[3] 李立君, 宋廷伦, 赵万忠, 等. 基于编码-解码网络的车道

[5] 叶荣, 何云, 高泉, 等. 基于 OpenCV 和模糊数学的茶叶病害分析方法研究 [J]. 北方园艺, 2024(4):145-153.

[6] 叶荣, 马自飞, 高泉, 等. 基于改进 YOLOv5s-ECA-ASFF 算法的茶叶病害目标检测 [J]. 中国农机化学报, 2024, 45(1): 244-251.

[7] LI L T, ZHAO Y D.Tea disease identification based on ECA attention mechanism ResNet50 network[J].Frontiers in plant science, 2025: 1489655.

[8] WU P, LIU J L, JIANG M F, et al.Tea leaf disease recognition using attention convolutional neural network and handcrafted features[J].Crop protection, 2025, 190: 107118.

[9] 王文明, 肖宏儒, 陈巧敏, 等. 基于图像处理的茶叶智能识别与检测技术研究进展分析 [J]. 中国农机化学报, 2020, 41(7): 178-184.

[10] 孙道宗, 刘欢, 刘锦源, 等. 基于改进 YOLOv4 模型的茶叶病害识别 [J]. 西北农林科技大学学报 (自然科学版), 2023, 51(9): 145-154.

【作者简介】

拓福婷 (1992—), 女, 陕西榆林人, 硕士研究生, 讲师、教研室主任, 研究方向: 人工智能与控制。

(收稿日期: 2025-03-18 修回日期: 2025-07-07)

线检测算法 [J]. 信息技术, 2023 (7): 17-23.

[4] 孙浩铭, 夏金泽, 胡盛辉, 等. 改进 UNet 与 DBSCAN 融合的车道线检测方法 [J]. 机械制造, 2023, 61 (4): 68-75.

[5] 程国建, 冯亭亭. 基于 DSA-UFLD 模型的车道线检测算法 [J]. 智能计算机与应用, 2023, 13 (3): 182-187.

[6] 江漫, 徐艳, 吕义付, 等. 基于计算机视觉的车道线检测技术研究进展 [J]. 信息技术与信息化, 2022 (11): 21-24.

[7] 常振廷, 肖智豪, 张文军, 等. 基于网格分类与纵横向注意力的城市道路车道线检测方法 [J]. 交通信息与安全, 2023, 41 (3): 92-102.

[8] 吕厚权, 杨小辉, 王登鹏. 用于辅助车辆驾驶的车道检测技术研究 [J]. 重型汽车, 2022 (4): 4-6.

[9] 许烁, 何俊红, 王栋. 基于改进双阈值分割的车道线检测算法研究 [J]. 工业控制计算机, 2021, 34 (8): 110-112.

[10] 蒋紫韵, 曹元元. 基于全卷积网络及 K-means 聚类算法的车道线检测的研究 [J]. 电子世界, 2021 (10): 101-103.

【作者简介】

王敬 (1986—), 女, 河北沧州人, 硕士, 讲师, 研究方向: 图像处理、目标检测。

(收稿日期: 2025-03-13 修回日期: 2025-07-07)