

杨蕴,汪韩燕,贾树良,等.基于车道线几何结构解析的车载单目图像车道检测[J].辽宁工程技术大学学报(自然科学版),2026,45(4):490-501.DOI:10.11956/j.issn.1008-0562.20260017

Yang Yun,Wang Hanyan,Jia Shuliang,et al.Lane detection on monocular on-vehicle images through geometric structure parsing of lane markings[J].Journal of Liaoning Technical University (Natural Science),2026,45(4):490-501.DOI:10.11956/j.issn.1008-0562.20260017

基于车道线几何结构解析的车载单目图像车道检测

杨 蕴¹,汪韩燕¹,贾树良²,郭欢欢¹

(1.河南城建学院 时空信息工程学院,河南 平顶山 467036;

2.辽宁工程技术大学 国有资产与实验室管理处,辽宁 阜新 123000)

摘 要:针对车载单目视觉在透视畸变、光照变化及车道线磨损等复杂场景的检测难题,以及嵌入式平台算力受限问题,提出一种基于车道线几何结构解析的轻量化检测方法。该方法不依赖复杂模型与大规模标注数据,通过显式建模车道线平行性、连续性等几何先验,构建自适应感兴趣区域提取-方向性边缘增强-改进逆透视变换-可靠区域选择-动态多项式拟合流程,实现车道特征增强与稳定提取。实验基于自建多场景数据集开展验证,涵盖直道、弯道、城市、夜间、雨天及鱼眼畸变等场景。研究结果表明:所提方法精确率、召回率与F1值分别达0.953、0.948和0.950,显著优于传统方法,且鲁棒性与精度优于两种分割类先进方法;无GPU加速下单帧平均处理时间为24.2 ms,满足车载实时性要求。研究结论为高级驾驶辅助系统与自动驾驶提供可靠环境感知支撑。

关键词:车道检测;单目视觉;几何结构解析;逆透视映射;动态多项式拟合;实时处理

中图分类号:TP391

文献标志码:A

文章编号:1008-0562(2026)04-0490-12

Lane detection on monocular on-vehicle images through geometric structure parsing of lane markings

Yang Yun¹, Wang Hanyan¹, Jia Shuliang², Guo Huanhuan¹

(1. School of Spatial-Temporal Information Engineering, Henan University of Urban Construction, Pingdingshan 467036, China; 2. Office of State-owned Assets and Laboratory Management, Liaoning Technical University, Fuxin 123000, China)

Abstract: To address the detection challenges of on-board monocular vision in complex scenarios such as perspective distortion, illumination variation and lane marking wear, as well as the limited computing power of embedded platforms, this paper proposes a lightweight detection method based on geometric structure parsing of lane markings. Free from reliance on complex models and large-scale annotated data, this proposed method explicitly models the geometric priors including parallelism and continuity of lane markings, and establishes a complete pipeline consisting of adaptive region of interest extraction, directional edge enhancement, improved inverse perspective transformation, reliable region selection and dynamic polynomial fitting to achieve the enhancement and stable extraction of lane features. The verification experiments are carried out on a self-built multi-scenario dataset covering straight roads, curved roads, urban roads, night, rainy days and fisheye distortion. The precision, recall and F1-score of the proposed method reach 0.953, 0.948 and 0.950 respectively, which are significantly better than those of traditional methods. Meanwhile, this method exhibits stronger robustness and higher accuracy than two advanced segmentation-based methods. The average processing time is 24.2 ms per frame without GPU acceleration, meeting the real-time requirement of vehicle-mounted applications. The research conclusions provide reliable environmental perception support for advanced driver assistance systems and autonomous driving.

收稿日期:2026-01-12 修回日期:2026-03-13 接受日期:2026-03-22 责任编辑:张雯

基金项目:河南省高等学校重点科研项目计划(25B420009);河南省科技攻关计划项目(262102321116);河南省科技研发计划联合基金(252103810061)

作者简介:杨 蕴(1990-),男,河南 南阳人,博士,讲师,主要从事车载视觉与遥感图像解析方面的研究。

E-mail: 20221026@huuc.edu.cn

Keywords: lane detection; monocular vision; geometric structure parsing; inverse perspective mapping; dynamic polynomial fitting; real-time processing

0 引言

随着高级驾驶辅助系统(advanced driver assistance systems, ADAS)与自动驾驶技术的规模化应用,车道检测作为环境感知的核心子模块,其实时性、鲁棒性及硬件适配性成为车载场景落地的关键制约因素^[1-2]。车载单目视觉系统凭借成本低廉、结构简单、信息丰富等优势,成为该领域的主流感知方案^[3],但透视畸变、光照不均、车道线磨损等问题给车道检测带来严峻挑战。如何在有限计算资源下实现高精度、实时的车道检测,是当前面临的重要技术瓶颈^[4]。

针对上述挑战,现有车道检测方法主要分为传统图像处理与深度学习两大类。传统方法通常依赖车道线的低层视觉特征和先验几何模型。例如,霍夫变换及其改进方法被广泛用于直线车道检测,李荣彬^[5]通过结合车道线平行与长度特性优化霍夫变换,提升结构化道路中的检测精度,但其对弯道及复杂曲率车道的适应性有限。为克服透视畸变影响,逆透视变换被引入以获取车道线的鸟瞰视图。刘景锋等^[6]提出改进的逆透视映射(inverse perspective mapping, IPM)算法,结合直方图粗定位与滑动窗口拟合实现车道检测,但在剧烈光照变化下稳定性不足。此外,部分研究侧重于自适应感兴趣区域与特征融合以提升鲁棒性。刘丹萍^[7]提出的感兴趣区域(region of interest, ROI)自适应定位方法,结合梯度引导与浅层网络学习,增强复杂场景下的检测能力,但仍需较多人工干预与参数调整。近年来,一些研究尝试将图像分割技术引入车道检测。王畅等^[8]提出一种融合图像分割与变尺度窗口的车道线距离检测方法,利用分割结果引导滑动窗口,提高距离测量的准确性。黄艳国等^[9]优化阈值分割结合滑动窗口,这些方法在特定场景下效果良好,但分割过程仍易受光照和阴影干扰。Zeng等^[10]将IPM与卡尔曼滤波结合用于车道跟踪,但模型灵活性不足。总体而言,传统方法计算量小、可解释性强,但在复杂场景下的泛化能力与精度难以兼顾。

近年来,深度学习推动了车道检测技术的显著进步,涌现出基于分割、关键点检测、曲线参数回归等多种范式。Lee等^[11]提出的VPGNet通过消失点引导多任务网络,有效融合车道与道路标

记的检测与识别。为追求更高的精度与结构化输出, PolyLaneNet 直接利用全连接层回归车道线的多项式系数^[12],简化了后处理流程。更高效的 Ultra-Fast-Lane-Detection 系列^[13]采用锚点驱动的有序分类思想,在速度与精度间取得了良好平衡。然而,这些高性能深度学习模型面临两大核心问题:其一,模型参数量大、计算复杂度高,严重依赖GPU算力,与低成本嵌入式平台的实时性要求存在根本矛盾^[14];其二,性能高度依赖大规模标注数据,在“长尾”场景下泛化能力下降且存在“黑箱”风险,难以满足安全性与可解释性要求^[15-16]。

鉴于此,本文回归车道线本质几何结构属性,面向无标注数据、算力受限的低成本车载嵌入式终端,提出一种轻量级、高鲁棒的车道检测方法。该方法不依赖复杂模型与海量数据训练,核心思想是充分利用车道线的平行性、连续性等强几何先验,通过图像处理流程进行显式建模与约束。具体而言,设计包含自适应感兴趣区域提取、方向性边缘增强、逆透视变换、可靠区域选择及动态多项式拟合的完整流程,旨在以较低计算代价实现复杂场景下的稳定检测。

1 算法描述

设原始待提取车载单目图像为 $I=\{I(x,y):(x,y)\in D\}$, 其中 (x,y) 表示像素格点位置; $D=\{(x,y):x=1,\dots,r;y=1,\dots,c\}$ 为图像空间域, r 和 c 分别为 D 的行数和列数; $I(x,y)=(I^R(x,y),I^G(x,y),I^B(x,y))$ 为 (x,y) 处像素的RGB矢量。

1.1 自适应感兴趣区域提取

对原图 I 进行灰度化处理, 转换式为

$$G(x,y)=w_R\cdot I^R(x,y)+w_G\cdot I^G(x,y)+w_B\cdot I^B(x,y), \quad (1)$$

式中: $G(x,y)$ 为 (x,y) 处像素的灰度值, $G=\{G(x,y):(x,y)\in D\}$ 为转换的灰度图像集合; w_R 、 w_G 和 w_B 分别为R、G和B通道的权重系数, 根据经验分别取0.299、0.587和0.114。

考虑到车道线通常位于图像的下半部分, 为了聚焦车道线相关信息并减少计算量, 选取图像的下半部分作为初步选择的感兴趣区域 G_{pre} , 即

$$G_{pre}=G\left(\left[\frac{r}{2}\right]:r,1:c\right), \quad (2)$$

式中, $\lceil \cdot \rceil$ 表示向上取整。

为实现多方向车道线边缘的精准提取, 设计 4 组 3×3 各向异性卷积模板: 水平模板左右列分别取 $[-1, -2, -1]$ 、 $[1, 2, 1]$, 中间列置 0; 垂直模板上下行分别取 $[-1, -2, -1]$ 、 $[1, 2, 1]$, 中间行置 0; 45° 和 135° 方向模板数值分别沿主、副对角线呈线性梯度分布, 以此定向强化不同走向的车道线边缘特征。利用 4 个模板, 分别对 G_{pre} 内坐标 $(x, y) \in D$ 执行卷积操作, 得到 4 个方向的偏导数 $D_1(x, y)$ 、 $D_2(x, y)$ 、 $D_3(x, y)$ 和 $D_4(x, y)$ 。由 4 个方向的偏导数计算总的边缘强度, 构造 G_{pre} 对应的梯度图像 $G_{\text{grad}} = \{G_{\text{grad}}(x, y) | (x, y) \in D\}$ 。计算式为

$$G_{\text{grad}}(x, y) = \sqrt{D_1(x, y)^2 + D_2(x, y)^2 + D_3(x, y)^2 + D_4(x, y)^2} \quad (3)$$

为进一步突出边缘特征, 对 G_{grad} 采用 Otsu 方法^[17], 自动确定阈值 T , 将梯度图转换为二值图像 $G_{\text{bi}} = \{G_{\text{bi}}(x, y) | (x, y) \in D\}$ 。计算式为

$$G_{\text{bi}}(x, y) = \begin{cases} 1 & G_{\text{grad}}(x, y) > T \\ 0 & G_{\text{grad}}(x, y) \leq T \end{cases} \quad (4)$$

在 G_{bi} 中, 选择半径为 7 的圆盘形结构元素 b , 进行形态学闭运算以填充空洞, 使车道线区域更加完整。计算式为

$$G_{\text{cl}} = (G_{\text{bi}} \oplus b) \ominus b, \quad (5)$$

式中: $G_{\text{cl}} = \{G_{\text{cl}}(x, y) | (x, y) \in D\}$; $\oplus$ 为膨胀操作; $\ominus$ 为腐蚀操作。

为筛选出潜在的车道线区域, 对 G_{cl} 进行连通区域分析^[18], 将其中面积最大的连通区域作为潜在的车道区域, 并由其最小外接矩形的顶点坐标、 G_{pre} 和 G , 得到提取的 ROI, 记为 $G_{\text{ROI}} = \{G_{\text{ROI}}(x, y) | (x, y) \in D_{\text{ROI}}\}$, 其中 D_{ROI} 的行数和列数分别为 N_r 和 N_c 。

1.2 车道线几何结构分析与透视变换

在 G_{grad} 中, 根据式 (4) 进行梯度幅值图阈值分割后, 构建自适应角度筛选器, 对梯度方向场进行梯形区域扫描。计算式为

$$\theta_{\text{edge}}(x, y) = \frac{D_1(x, y)}{D_2(x, y)} \quad (6)$$

设置角度容限区间 $\theta \in [\theta_{\min}, \theta_{\max}]$, 仅保留与车道线梯形投影特征匹配的边缘响应。设置左车道线 $30^\circ \sim 80^\circ$ 、右车道线 $120^\circ \sim 170^\circ$ 角度容限, 保留匹配梯形投影特征的边缘, 据此得到梯形筛选图 B_θ 。

为了强化车道标线的几何连续性, 对 G_{ROI} 按

式 (4) 分割获得二值图 B_{pre} , 并与梯形筛选图 B_θ 进行局部邻域内的空间一致性检验操作, 局部一致性测度计算式为

$$B(x, y) = \begin{cases} 1 & \sum_{m, n \in \Omega_k} B_\theta(m, n) \wedge B_{\text{pre}}(m, n) \geq \tau \\ 0 & \text{其他} \end{cases} \quad (7)$$

式中: Ω_k 表示以 $(x, y) \in D_{\text{ROI}}$ 为中心的 $k \times k$ 邻域窗口; τ 为实验确定的置信度阈值; $\wedge$ 表示逻辑与操作; $B = \{B(x, y) | (x, y) \in D_{\text{ROI}}\}$ 表示在 G_{ROI} 内构建的具有明确几何语义的车道线特征图谱, 为后续透视变换提供关键的数据支持。

为消除相机透视畸变, 使汇聚的车道线呈现平行特征, 采用改进的逆透视映射 (inverse perspective mapping, IPM) 算法将 B 转换为鸟瞰视图, 该过程通过 3 个核心阶段实现。

首先, 进行坐标系归一化, 将原始图像坐标系平移至以 G_{ROI} 中心为原点的相对坐标系。对于尺寸为 $N_r \times N_c$ 的 G_{ROI} 区域, 像素位置 (x, y) 通过式 (8) 转换为归一化坐标 (X, Y) , 以确保后续旋转操作围绕视觉中心展开。

$$\begin{cases} X = x - N_c/2 \\ Y = y - N_r/2 \end{cases} \quad (8)$$

其次, 进行三维空间变换, 构建包含旋转和平移的变换矩阵 T , 其参数依据车载相机安装角度优化。通过矩阵乘法实现像素坐标的射影变换, 计算式为

$$\begin{pmatrix} p \\ q \\ l \\ 1 \end{pmatrix} = T \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix}, \quad T = \begin{pmatrix} s_x \cos \beta & 0 & -\sin \beta & 0 \\ 0 & s_y & 0 & 0 \\ \sin \beta & 0 & \cos \beta & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

式中: (p, q, l) 为旋转图像的位置; β 为绕 Z 轴旋转的角度; s_x 和 s_y 为在垂直和水平方向拉伸的高度。

最后, 进行透视投影优化, 采用针孔相机模型将三维坐标投影至二维鸟瞰 (BEV) 平面。投影公式结合焦距参数 f 实现, 计算式为

$$u = \frac{f \cdot p}{f - l + \delta} + \frac{N_c}{2}, \quad v = \frac{f \cdot q}{f - l + \delta} + \frac{N_r}{2},$$

式中: δ 为数值稳定性补偿因子; (u, v) 为投影到二维 BEV 平面的输出像素坐标。设 $P = \{P(u, v) | (u, v) \in D_p\}$ 为鸟瞰图像集合, 其中 D_p 的行数和列数分别为 A_r 和 A_c 。

1.3 车道检测区域评估与选择

在 P 中, 车道线像素呈现列方向聚集特征, 故沿 P 的水平方向生成列直方图 $H(v)$, 表示 P 中第 v

列候选车道像素数,表达式为

$$H(v) = \sum_{u=1}^{A_c} P(u, v) \quad v = 1, 2, \dots, A_c。$$

为了反映车道线在列方向上的聚集程度,以车辆中心线为分界将直方图分为左右区域,求解区域峰值:左区域峰值 $p_{lc} = \max\{H(v) | v \in [1, A_c/2]\}$,右区域峰值 $p_{rc} = \max\{H(v) | v \in [A_c/2 + 1, A_c]\}$ 。以 $P(u, v)$ 作为权重,计算左、右车道基准列加权均值 μ_{lc} 和 μ_{rc} ,可表示为

$$\mu_{lc} = \frac{2}{A_c} \sum_{v=1}^{A_c/2} \sum_{u=1}^{A_c} v \cdot P(u, v),$$

$$\mu_{rc} = \frac{2}{A_c} \sum_{v=A_c/2+1}^{A_c} \sum_{u=1}^{A_c} v \cdot P(u, v)。$$

基于加权均值计算标线列位置的加权标准差 σ_{lc} 和 σ_{rc} ,以反映车道线像素的分散程度,计算式为

$$\sigma_{lc} = \sqrt{\frac{2}{A_c} \sum_{v=1}^{A_c/2} \sum_{u=1}^{A_c} P(u, v) \cdot (v - \mu_{lc})^2},$$

$$\sigma_{rc} = \sqrt{\frac{2}{A_c} \sum_{v=A_c/2+1}^{A_c} \sum_{u=1}^{A_c} P(u, v) \cdot (v - \mu_{rc})^2}。$$

为实现左右车道区域量化评估,综合标线明显度(峰值)与位置稳定度(标准差)构建可靠性评价指标。左、右车道可靠性评估标准计算式为

$$R_{lc} = tp_{lc} - \sigma_{lc}, \quad R_{rc} = tp_{rc} - \sigma_{rc},$$

式中, t 为峰值和标准偏差之间的权衡参数。

对比左右区域的可靠性,如果 $R_{lc} \geq R_{rc}$,则以左车道区域为检测基准;反之选择右车道区域为检测基准。

1.4 车道模型解析与拟合

考虑到车道可能弯曲,在所选可靠车道区域中,以直方图峰值列索引 p_{lc} 或 p_{rc} 为初始基准,采用动态滑动窗口逐行扫描。设定固定高度 h 和宽度 w 的矩形窗口,从图像底部向上移动,窗口横向位置 x_{center} 由前一窗口内车道像素的横坐标均值动态更新,计算式为

$$x_{center}^{(k)} = \frac{1}{K} \sum_{u=1}^K x_u^{(k-1)},$$

式中, K 为前一窗口内有效车道像素数量。

对窗口内提取的车道像素点集 $\{(v_i, u_i)\}$,采用二阶多项式对车道几何曲线进行拟合,其表达式为

$$u(v) = a_0 + a_1 v + a_2 v^2,$$

式中, a_0 、 a_1 、 a_2 为拟合参数。

拟合过程通过最小化残差平方和实现,对窗口内每个点 (v_i, u_i) 构建矩阵 A 和向量 B 。

$$A = \begin{bmatrix} v_1^2 & v_1 & 1 \\ v_2^2 & v_2 & 1 \\ \vdots & \vdots & \vdots \\ v_K^2 & v_K & 1 \end{bmatrix}, \quad B = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_K \end{bmatrix}。$$

通过方程 $A^T A a = A^T B$, 计算多项式系数 $a = (a_0, a_1, a_2)^T$, 即

$$a = (A^T A)^{-1} A^T B。$$

将拟合参数代入 $u(v)$ 生成车道线预测模型。为生成对侧车道线,将可靠车道多项式模型沿水平方向平移至对侧区域的峰值列位置,平移距离 Δx 由可靠车道基准列索引与对侧区域峰值列索引之差确定,计算式为

$$\Delta x = p_{rc} - p_{op},$$

式中: p_{rc} 为可靠车道区域的直方图峰值列索引(如 p_r); p_{op} 为对侧区域的直方图峰值列索引(如 p_l)。

将计算得到的车道多项式移动到另一区域的峰值列位置,以获得第二条车道线。计算式为

$$u'(v) = u(v) + \Delta x。$$

2 实验结果与分析

基于 Windows 10 系统搭建实验平台,硬件配置为 16G 内存、i7-7700K CPU,无 GPU 加速(模拟车载嵌入式平台算力约束)。依托 MATLAB R2020b 完成算法编写仿真测试,验证本文方法的有效性、鲁棒性与实时性。

2.1 实验数据及设置

实验采用自建的车载单目图像数据集,由主流记录仪采集,涵盖白天、夜晚及雨天等多种环境,包含直道/弯道、清晰/磨损车道线、标准/鱼眼畸变、夜间/雨天等场景,共计约 2 000 帧标注图像,见图 1 和图 2。图 1 为日间典型场景:图 1 (a) 高速车道 (720×1 280 像素)、图 1 (b) 乡村车道 (562×1 088 像素)、图 1 (c) 弯曲车道 (768×1 280 像素)、图 1 (d) 城市车道 (590×1 640 像素);图 1 (e)、图 1 (f) 为鱼眼图像 (478×631 像素、480×640 像素)。图 2 为夜间和雨天场景 (506×1 000 像素)。




图1 原始车载单目车道图像

Fig.1 Original onboard monocular lane images



图2 雨天及夜晚场景原始车载单目车道图像

Fig.2 Original monocular lane images under rainy and night scenarios

对比算法采用多层次对比方案。选取文献[5]的霍夫变换方法和文献[7]的ROI自适应定位方法作为基线对比,验证本文相较于传统方法的优势;选取文献[8]的融合分割与变尺度窗口方法、文献[9]的优化阈值分割与滑动窗口方法,验证本文几何结构解析路线的竞争力。实验未纳入依赖GPU的轻量化深度学习模型,因其数据依赖性和部署成本与本文面向的无样本、算力受限的车载场景存在根本差异。为定量评价检测精度,采用精确率(Precision)、召回率(Recall)、F1值作为评价指标^[9],三者分别反映检测准确性、车道线覆盖能力与综合性能。

2.2 自适应ROI提取结果与分析

从图1和图2的原始图像可以看出,车道标线集中在图像下半部分。本文以图像下半部分作为初步ROI,通过4个各向异性卷积模板计算梯度图,采用Otsu法进行阈值化,得到二值分割结果。受光照、磨损等因素影响,车道标线内部或段间可能出现空洞或断裂,通过圆盘形结构元素的闭运算进行填充,使车道标线区域更加完整连续,再利用连通区域分析提取最终ROI。

为展示自适应ROI提取的必要性,将初步ROI(绿色)和最终ROI(红色)叠加至原图,见图3。

图像下半部分可排除大部分非车道干扰,选择最大连通区域能使ROI准确覆盖车道标线,有效排

除路肩、车辆、植被等干扰,为后续处理提供特征聚焦的输入图像。




图3 初步和最终ROI的叠加结果

Fig.3 Preliminary and final ROI overlay results

2.3 车道线几何与透视变换结果与分析

梯度图中既包含真实车道线边缘,也包含噪声、光照变化等产生的虚假边缘。为突出显著边缘并削弱噪声干扰,对梯度图像进行阈值分割处理,使车道线边缘更加突出。在此基础上,为识别与车道线梯形投影特征匹配的边缘方向,设定右车道线角度容限为 $120^{\circ}\sim 170^{\circ}$,左车道线为 $30^{\circ}\sim 80^{\circ}$,通过方向约束机制仅保留与梯形投影特征相符的边缘信息,显著提高了车道线检测的准确性

和可靠性。

为进一步强化车道标线的几何连续性,对梯形筛选和二值结果进行局部邻域空间一致性检验,通过定义局部一致性测度,计算每个像素点在 5×5 邻域窗口内的空间一致性,经逻辑与操作构建出具有明确几何语义的车道线特征图,见图4。该特征图谱保留了关键车道线特征并强化了几何连续性,为后续透视变换和车道线检测提供了更准确可靠的数据支持。




图4 车道标线特征的局部邻域空间一致性强化

Fig.4 Local neighborhood spatial consistency enhancement of lane marking features

相机透视畸变会导致实际平行的车道线在图像中汇聚,影响车道线识别、定位与参数计算。为此采用改进IPM将特征图谱 B 转换为鸟瞰视图 P ,车

道1~车道6的转换结果见图5(a)~图5(f)。经IPM校正后,车道线恢复平行结构,还原真实空间关系,为后续车道线检测定位提供精准视角。




图 5 ROI 的鸟瞰图转换结果

Fig.5 ROI bird's-eye view conversion results

2.4 车道线提取与拟合结果分析

以 ROI1 为例, 通过对鸟瞰图 P 进行列直方图统计分析, 得到水平投影直方图, 见图 6。




图 6 ROI1 的水平投影直方图

Fig.6 Horizontal projection histogram of ROI1

直方图左右区域均出现明显峰值, 说明车道线像素呈列方向高度聚集。通过计算左右区域峰值、加权均值与标准差, 可量化车道线检测可靠

性。图 6 中右车道区域的峰值 p_r 和均值 μ_r 较高、标准差 σ_r 较小, 表明其像素分布集中、可靠性较高; 左车道区域则相反。根据可靠性评估标准, 选择右车道区域作为后续提取基准。结果表明, 直方图统计与动态权衡机制可有效优选高置信度车道区域, 为车道线提取提供可靠支撑, 提升检测鲁棒性与准确性。

在可靠车道区域, 通过动态滑动窗口逐行扫描车道线, 采用二阶多项式拟合生成车道线预测模型, 并将其沿水平方向平移至对侧区域的峰值列位置, 获得第二条车道线, 最终生成完整的道路标线提取结果, 见图 7。不同 ROI 内提取的车道线与鸟瞰图中的实际车道线高度吻合, 能够准确反映车道几何特征和弯曲情况。动态滑动窗口与二阶多项式拟合既能适应弯道, 又能抑制噪声, 确保提取的准确性和鲁棒性。对侧车道线的生成进一步验证了车道模型解析方法的有效性。




图 7 ROI 鸟瞰图的道路标线提取结果及叠加

Fig.7 Lane marking extraction results and overlay of bird's-eye view image

将鸟瞰图中的二值车道线重新投影回原始透视图, 并以红色叠加在原始图像上, 形成的叠加效果见图 8。本文算法在不同场景下均展现出良好的车道检测能力。对于状态良好的车道, 即使附近存在标志等干扰物 (见图 8 (c)), 算法也能精准识

别。当车道存在阴影或被车辆占用时, 算法依然能有效检测, 具备较强的鲁棒性。此外, 针对单条车道、车道磨损、车道线非平行、道路弯曲以及城市道路上方存在多类标识等特殊工况, 均可实现正确检测。上述实验结果表明, 本文算法在

多种复杂车道场景下均具备良好的检测可靠性与

环境适应性。




图8 车道标线的最终提取结果叠加

Fig.8 Overlay of the final extraction results of lane markings

2.5 对比实验分析

将本文算法与文献[5]、文献[7]所提方法的检测结果开展可视化对比,见图9和图10。文献[5]方法基于霍夫变换,在直道场景(图9(a)、图9(b))能实现基本检测,但在弯道场景(图9(c))仅能拟合直线段,出现“折线化”偏差;在车道线磨损/遮挡场景(图9(d)、图9(e))因缺

乏几何连续性约束,检测出现断裂;在鱼眼畸变场景(图9(f))适应性差,误检与漏检并存。文献[7]方法通过自适应ROI聚焦车道区域,但未引入几何结构约束,在复杂背景干扰(图10(d))下易将路面标志、阴影等误判为车道线,精确率下降;在车道线不完整场景(图10(c)、图10(f))断裂处无法有效连接,召回率不足;在鱼镜头场ROI定位未考虑畸变校正,拟合结果出现偏移。




图9 文献[5]方法的提取结果叠加

Fig.9 Overlay of extraction results of the method in reference [5]




图 10 文献[7]方法的提取结果叠加

Fig.10 Overlay of extraction results of the method in reference [7]

为全面量化各算法的综合检测性能，对6类测试场景的检测结果进行定量统计，精确率、召回率、F1 值与单帧平均处理耗时如表 1 所示。

表 1 实验结果定量性能对比


Tab.1 Quantitative performance comparison of experimental results

算法	精确率	召回率	F1 值	单帧处理时间/ms
文献[5]	0.862 ± 0.045	0.847 ± 0.051	0.854 ± 0.043	30.2 ± 1.8
文献[7]	0.885 ± 0.038	0.873 ± 0.042	0.879 ± 0.036	34.7 ± 2.1
本文	0.953 ± 0.021	0.948 ± 0.025	0.950 ± 0.022	24.5 ± 1.3

注：“±”之前为平均值,之后为标准差。


本文算法的精确率、召回率和 F1 值均显著优于文献[5]和文献[7]，表明几何结构约束有效减少了误检，动态滑动窗口与多项式拟合提升了不完整车道线的捕捉能力。实时性方面，本文算法单帧平均处理时间为 24.5 ms，满足实时性要求，较文献[7]明显提升，同时小幅优于文献[5]算法。

为进一步验证本文方法在低光照、复杂天气下的性能，选取夜间及雨天场景（见图 2）进行实验，并与文献[8]和文献[9]两种基于图像分割的方法进行对比。所有对比方法均以自适应提取的 ROI 区域为输入。本文方法自适应 ROI 筛选结果见图 11。





(e) 车道 11-夜晚



(f) 车道 12-夜晚

图 11 雨天及夜晚场景自适应 ROI 的提取结果

Fig.11 Extraction results of adaptive ROI in rainy and night scenes

即使在低照度和雨水干扰下, 本文的 ROI 提取方法仍能有效定位车道线所在的主要区域。车道线在 IPM 空间中被有效增强和分离, 最终提取结果的叠加效果见图 12。无论是在城市道路、乡

村道路还是雨点干扰严重的场景, 本文方法均能稳定、准确地检测出车道线, 体现出良好的复杂环境泛化能力。




(a) 车道 7




(b) 车道 8




(c) 车道 9



(d) 车道 10



(e) 车道 11




(f) 车道 12

图 12 雨天及夜晚场景车道标线的最终提取结果叠加

Fig.12 Overlay of the final extraction results of lane markings in rainy and night scenes

文献[8]和文献[9]方法的提取结果叠加见图 13 和图 14。文献[8]方法虽能检测出部分车道线段, 但在夜间场景下受噪声影响, 误检和断裂现象较

多, 检测完整性不足。文献[9]方法在部分城市夜间场景表现尚可, 但在低对比度场景中难以完整提取车道线, 对雨水干扰较为敏感。




(a) 车道 7



(b) 车道 8



(c) 车道 9



(d) 车道 10



图 13 文献[8]方法提取结果的叠加

Fig.13 Overlay of extraction results of the method in reference [8]




图 14 文献[9]方法提取结果的叠加

Fig.14 Overlay of extraction results of the method in reference [9]

针对夜间、雨天等复杂场景进行定量指标统计,结果见表2。本文方法在复杂环境下的精确率、召回率均超0.94,F1值达0.941,性能稳健。文献[8]、文献[9]的F1值仅为0.861、0.873,场景适应性不足。本文依托几何结构解析强化车道本质特征,而非单纯依赖边缘信息,能够有效抑制噪声与背景干扰。

表2 夜间及雨天场景检测结果定量性能对比

Tab.2 quantitative performance comparison on night and rainy scenes

算法	精确率	召回率	F1值	每帧处理时间/ms
文献[8]	0.874 ± 0.052	0.848 ± 0.061	0.861 ± 0.055	31.5 ± 2.0
文献[9]	0.891 ± 0.044	0.856 ± 0.058	0.873 ± 0.049	32.8 ± 2.3
本文	0.944 ± 0.028	0.938 ± 0.033	0.941 ± 0.030	21.1 ± 1.5

注:“±”之前为平均值,之后为标准差。

综合定性与定量结果表明,本文方法通过车道线显式建模,结合自适应ROI、改进IPM与动态多项式拟合,在多类复杂场景下检测稳定准确。相较传统方法与分割类方法,弯道适配性、抗干扰性与检测完整性更优,且高精度下速度更快,轻量化与实时性优势突出。

2.6 核心参数分析与讨论

本文方法的核心参数取值均通过实验确定,下面对几个关键参数进行分析。

(1) 角度容限区间(左车道 $30^{\circ} \sim 80^{\circ}$,右车道 $120^{\circ} \sim 170^{\circ}$)。该参数依据相机安装位置与透视几何模型设定。实验表明,收窄 10° 会略降召回率,放宽 10° 会引入噪声,当前取值在精确率与召回率间达到最优平衡,对相机俯仰角微小变化不敏感。

(2) 邻域窗口大小 k 和置信度阈值 τ 。 k 设为 5×5 ,兼顾计算效率与几何约束效果; τ 设为0.6,在 $0.5 \sim 0.7$ 范围内变化时F1值波动小于1%,算法对该参数不敏感。

(3) 滑动窗口高度 h 和宽度 w 。 h 取鸟瞰图高度的 $1/10$, w 取宽度的 $1/8$,可确保采样点充足并排除邻道干扰。两参数与IPM变换后尺度相关,实际应用中可根据输出图像尺寸等比例调整。

3 结论

本文提出一种基于车道线几何结构解析的车载单目车道检测方法,通过自适应ROI提取-几何结构约束-改进逆透视变换-可靠区域选择-动态多项式拟合流程,显式建模车道线平行性与连续性

先验,无需标注数据与GPU加速。方法将方向性边缘增强、改进IPM与动态拟合结合,有效消除透视畸变,提升破损车道线检出能力。多场景实验表明:本文方法精确率、召回率、F1值分别达0.953、0.948、0.950,显著优于传统方法;夜间与雨天场景F1值达0.941,优于两类分割对比方法;无GPU加速下单帧耗时24.5 ms,满足车载实时检测需求。低纹理路面与严重遮挡场景下鲁棒性不足,后续将融合多传感器时空跟踪,并拓展车道线类型识别功能。

参考文献(References):

- [1] Gaikwad V, Lokhande S. Lane departure identification for advanced driver assistance[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 910-918.
- [2] 叶欣辰,王雪松,田炜. 基于车道检测性能的自动驾驶车辆平原地区高速公路适驾性评估[J]. 中国公路学报, 2024, 37(11): 220-234.
Ye Xincheng, Wang Xuesong, Tian Wei. Readiness evaluation on freeways in plain regions for automated vehicles based on lane detection performance[J]. China Journal of Highway and Transport, 2024, 37(11): 220-234.
- [3] Pittner M, Janai J, Condurache A P. LaneCPP: continuous 3D lane detection using physical priors[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 10639-10648.
- [4] 马庆禄,张丽,马恋,等. 面向自动驾驶的隧道车道线AI自适应识别方法[J]. 西南交通大学学报, 2026, 61(2): 452-465.
Ma Qinglu, Zhang Li, Ma Lian, et al. AI adaptive recognition method for tunnel lane lines in autonomous driving[J]. Journal of Southwest Jiaotong University, 2026, 61(2): 452-465.
- [5] 李荣彬. 基于霍夫变换算法的车载视频车道线检测[J]. 电脑编程技巧与维护, 2024(2): 131-134.
Li Rongbin. Lane detection of vehicle video based on Hough transform algorithm[J]. Computer Programming Skills & Maintenance, 2024(2): 131-134.
- [6] 刘景峰,李炎亮,江奎,等. 基于改进逆透视变换的车道线检测算法[J]. 智能计算机与应用, 2021, 11(3): 109-112.
Liu Jingfeng, Li Yanliang, Jiang Kui, et al. Lane detection algorithm based on inverse perspective transform[J]. Intelligent Computer and Applications, 2021, 11(3): 109-112.
- [7] 刘丹萍. 基于ROI自适应定位的复杂场景车道线检测[J]. 长春师范大学学报, 2020, 39(10): 66-70.
Liu Danping. Lane detection for complex scene based on ROI adaptive location[J]. Journal of Changchun Normal University, 2020, 39(10): 66-70.
- [8] 王畅,李勇杭,张凯超,等. 基于融合分割和变尺度窗口的车道线距离检测[J]. 中国公路学报, 2023, 36(7): 212-222.
Wang Chang, Li Yonghang, Zhang Kaichao, et al. Lane line distance detection based on fusion segmentation and a variable-scale window[J]. China Journal of Highway and Transport, 2023, 36(7): 212-222.
- [9] 黄艳国,钟勇,饶泽浩. 基于优化最大类间方差阈值分割与滑动窗口法的车道偏离预警[J]. 汽车技术, 2023(6): 9-16.
Huang Yanguo, Zhong Yong, Rao Zehao. Lane departure warning based on optimized threshold segmentation of maximum inter-class variance and sliding window method[J]. Automobile Technology, 2023(6): 9-16.
- [10] Zeng L J, Ao B Q, Li Q. Lane-line detection based on inverse perspective mapping and Kalman filter[J]. Advances in Engineering Technology Research, 2024, 11(1): 1.
- [11] Lee S, Kim J, Yoon J S, et al. VPGNet: vanishing point guided network for lane and road marking detection and recognition[C]//2017 IEEE International Conference on Computer Vision. October 22-29, 2017, Venice. IEEE, 2017: 1965-1973.
- [12] Tabelini L, Berriel R, Paixo T M, et al. PolyLaneNet: lane estimation via deep polynomial regression[C]//2020 25th International Conference on Pattern Recognition. January 10-15, 2021, Milan, Italy. IEEE, 2021: 6150-6156.
- [13] Guo A W, Li M Y, Liu D K, et al. Lane detection in complex scenes based on ultra-fast structure-aware[J]. Highlights in Science, Engineering and Technology, 2024, 119: 783-791.
- [14] 李阳,赵娟,严运兵. 基于改进型YoloV5s的热红外道路车辆及行人检测方法[J]. 智能计算机与应用, 2022, 12(6): 33-38.
Li Yang, Zhao Juan, Yan Yunbing. Thermal infrared road vehicle and pedestrian detection method based on improved YoloV5s[J]. Intelligent Computer and Applications, 2022, 12(6): 33-38.
- [15] 娄路,胡振坤,魏文洁,等. 复杂道路场景下智能驾驶单目3D车道线检测[J]. 计算机应用研究, 2025, 42(12): 3807-3814.
Lou Lu, Hu Zhenkun, Wei Wenjie, et al. Monocular 3D lane detection for intelligent driving in complex road scenarios[J]. Application Research of Computers, 2025, 42(12): 3807-3814.
- [16] Jain M. Lane line detection[J]. International Journal for Research in Applied Science and Engineering Technology, 2024, 12(4): 4932-4938.
- [17] 刘娜,戴激光. 一种表达图像地物边缘的线段序列检测方法[J]. 辽宁工程技术大学学报(自然科学版), 2024, 43(2): 208-216.
Liu Na, Dai Jiguang. A line segment sequence detection method for expressing image object edge[J]. Journal of Liaoning Technical University (Natural Science), 2024, 43(2): 208-216.
- [18] Peng Y, Chen Z, Wu Q M J, et al. Traffic flow detection and statistics via improved optical flow and connected region analysis[J]. Signal, Image and Video Processing, 2018, 12(1): 99-105.
- [19] Sadeli A F, Lawanda I I. Recall, precision, and F-measure for evaluating information retrieval system in electronic document management systems (EDMS) [J]. Khizanah al-Hikmah: Jurnal Ilmu Perpustakaan, Informasi, dan Kearsipan, 2023, 11(2): 231-241.