

DOI: 10.13382/j.jemi.B2508434

先验引导的多尺度车道线检测网络*

张全¹ 周甯¹ 刘洋毅² 段昶³

(1. 西南石油大学计算机与软件学院 成都 610500; 2. 智能警务四川省重点实验室 泸州 646000;

3. 西南石油大学电气信息学院 成都 610500)

摘要:精准的车道线信息对于自动驾驶系统中的路径规划和决策模块至关重要。为实现高精度的车道线检测,将车道线细长且结构连续的特点作为先验信息,提出一种先验引导的多尺度车道线检测网络。该网络以 Resnet-18 作为主干特征提取结构,在不同阶段引入门控融合模块,有效抑制了冗余信息传播,提高了跨层信息交互效率。针对车道线细长、连续、跨越大范围空间的特点,在 FPN 网络中引入了大核注意力机制,显著扩大感受野,增强网络对不同尺度车道线的感知能力。在检测头部分,结合了车道先验和全局特征,有效解决了仅依赖局部像素难以准确识别车道线的问题。此外,设计辅助分割分支并采用交叉熵损失函数,以优化参数更新过程,增强模型在细粒度特征上的表达能力。实验表明,在 TuSimple 数据集上精确度达到 96.96%; CULane 数据集上取得了 80.1% 的 F1 分数,该方法在复杂场景能够实现高精度的车道线检测,且在现有的车道线检测方法中展现出很强的竞争力。

关键词: 车道线检测; 车道先验; 注意力机制; 特征融合; 交叉熵损失

中图分类号: TP391.41; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4

Multi scale lane detection network guided by prior guidance

Zhang Quan¹ Zhou Ning¹ Liu Yangyi² Duan Chang³

(1. School of Computer Science and Software Engineering, Southwest Petroleum University, Chengdu 610500, China;

2. Intelligent Policing Key Laboratory of Sichuan Province, Luzhou 646000, China; 3. School of Electrical Engineering and Information, Southwest Petroleum University, Chengdu 610500, China)

Abstract: Accurate lane line information is crucial for path planning and decision-making modules in autonomous driving systems. To achieve high-precision lane detection, this paper leverages the inherent characteristics of lane lines—being slender and structurally continuous—as prior knowledge, proposing a lane-prior guided multi-scale lane detection network. The network employs ResNet-18 as the backbone feature extraction structure. Gated fusion modules are introduced at different stages to effectively suppress redundant information propagation and enhance cross-layer information interaction efficiency. Addressing the slender, continuous, and spatially extensive nature of lane lines, a large kernel attention mechanism is incorporated into the feature pyramid network (FPN), significantly expanding the receptive field and strengthening the network's perception capability for lane lines across different scales. In the detection head, lane priors are combined with global features, effectively resolving the challenge of accurately identifying lane lines when relying solely on local pixels. Furthermore, an auxiliary segmentation branch is designed, utilizing a cross-entropy loss function to optimize the parameter update process and enhance the model's expressive power for fine-grained features. Experiments conducted on the public TuSimple and CULane datasets demonstrate the effectiveness of the proposed method: it achieves 96.96% accuracy on the TuSimple dataset and an F1-score of 80.1% on the CULane dataset. The proposed method enables high-precision lane detection in complex scenarios and exhibits strong competitiveness among existing lane detection approaches.

Keywords: lane detection; lane prior; attention mechanism; feature fusion; cross entropy loss

收稿日期: 2025-06-03 Received Date: 2025-06-03

* 基金项目: 智能警务四川省重点实验室开放课题(ZNJW2024KFMS003)、泸州市应用基础研究(2024JYJ055)资助项目

0 引言

随着智能交通与自动驾驶技术的迅速发展,车道线检测作为环境感知的关键环节,受到了广泛关注。车道线检测主要任务是从车辆前方的道路图像中准确识别并定位车道线,为后续的路径规划与车辆控制提供可靠依据。

目前车道线检测方法主要分为两种:传统的车道线检测方法和基于深度学习的车道线检测方法。传统的车道线检测方法依赖于颜色、纹理等低层视觉特征,通过参数化模型对车道线的几何形态进行建模与拟合,从而实现车道线的提取与定位。范晖等^[1]基于参数预测算子进行车道建模,并结合 Kalman 滤波器进行跟踪优化,提升了车道线检测的准确性。Xu^[2]通过引入 HSL 颜色空间,有效提升了车道线的检测能力;而 PolyLaneNet^[3]将车道检测问题建模为多项式回归任务归实现了高效的车道线检测。然而, PolyLaneNet 由于上下文信息建模能力的不足,在面对复杂场景时检测精度较差。传统的车道线检测方法在标准道路环境下表现尚可,但在实际复杂道路中往往效果欠佳。

基于深度学习的车道线检测方法主要包括两类,一类是基于分类的方法,另一类是基于分割的方法。基于分类的车道线检测方法通常将图像划分为若干可学习的区域或单元,并将检测任务转化为对每个区域逐行进行分类的问题。Qin 等^[4]在图像上预设行锚点来表示表示车道线,将车道线检测任务转化为行锚点分类任务,提升了检测效率,但在精度方面有所欠缺。李沐原等^[5]通过引入 MDFA 模块和 ASPP 模块提高了网络的感受野,增强了模型对于车道线的感知能力,然而其检测准确率依旧有限。

基于分割的车道线检测方法通常将该任务建模为语义分割问题,即通过对每个像素点进行预测的方式将车道区域从背景中精准区分开。Pan 等^[6]提出了 SCNN 方法,该方法提出的消息传递机制能够捕获车道之间的像素空间信息,实现了较高的检测精度。Zheng 等^[7]提出了一种实时特征聚合模块 RESA,通过周期性切片机制增强网络对全局特征的聚合能力,从而提升整体检测性能。潘玉恒等^[8]引入生成对抗网络以扩充数据集,并且在 ResNeXt 网络的基础上提出改进,提出 SGRNeXt 网络,提高了检测精度。Neven 等^[9]将检测过程视为像素级分割任务,提出包含两个检测分支的 LaneNet 网络,保证了较高的检测精度。蒯晓等^[10]在编码部分采用分支结构网络并在其中应用注意力机制,解码部分使用跳跃连接以实现不同层级的特征融合,检测精度有一定提高,但在复杂场景下的检测精度仍

有提升空间。Liu 等^[11]基于条件卷积提出了一种自顶向下的检测网络 CondLaneNet,有效提升了网络对车道信息的处理能力。此外, Hou 等^[12]提出了利用自注意力机制的蒸馏方法 SAD,进一步增强了网络对车道线细节信息的捕捉能力。基于分割的方法往往只是对整幅图像进行逐像素预测,而没有利用到车道线本身具有的连续、细长等特点。

本文利用车道线细长且结构连续的特点,将其作为车道先验信息,以 CLRN^[13]作为基准模型,提出一种基于先验引导的多尺度车道线检测网络,来提升车道线在复杂场景中的检测精度与鲁棒性。最后,在 TuSimple 和 CULane 数据集上验证了本文方法有效性。

本文提出门控融合模块,将门控融合模块添加到 Resnet-18 中,以加强跨层语义信息交互能力,解决原来 Resnet-18 易造成有用信息被稀释或干扰的问题;在特征金字塔网络(feature pyramid network, FPN)^[14]的横向连接中引入大核注意力,增强网络感受野的同时,提高网络对车道线的感知能力;设计辅助分割损失函数以提升监督信号的丰富性,优化模型参数,强化模型在细粒度层面的表达能力,进一步提高检测精度。

1 先验引导的多尺度车道线检测网络

1.1 车道先验

车道线具有形状细长且连续的特点,将其作为车道先验可以帮助网络更好地定位真实车道线位置。在目标检测任务中,通常采用矩形框表示检测对象。然而车道线结构细长,用矩形框表示车道线容易导致检测精度下降。本文使用二维点构成的序列 P 表示车道线, P 的表达式如式(1)所示。

$$P = \{(x_1 + offset_1, y_1), \dots, (x_N + offset_N, y_N)\} \quad (1)$$

式中: N 是采样点数; $offset_N$ 表示第 N 组点上的横坐标偏移量,每组采样点的纵坐标 y_i 是在图像垂直方向进行等间距采样取得,其表达式如式(2)所示。

$$y_i = \frac{H}{N-1} \times i \quad (2)$$

式中: H 是图像高度。

每个车道先验由网络预测得到,包括4个分量:1)前景和背景的概率;2)先验车道的长度;3)起始点坐标 (x_0, y_0) 和与 x 轴的夹角 θ ;4) N 个偏移量,即预测点与实际车道线的水平距离,本文模型中 N 设置为 72,车道先验与车道线关系如图 1 所示。

1.2 网络结构

本文的检测网络结构如图 2 所示,整体结构由 Resnet-18、FPN、检测头以及辅助分割4部分组成。主干网络采用 Resnet-18 进行特征提取,针对深层网络细节特




图1 车道先验与车道线关系

Fig. 1 Relationship between lane prior and lane line




图2 网络结构

Fig. 2 Network architecture diagram

1.3 门控融合模块

ResNet 通过引入残差连接,虽然有效缓解了深层网络梯度消失的问题,然而,ResNet 的各级残差块之间主要依赖简单的逐层堆叠结构,缺乏显式的特征选择与信息筛选机制。这种设计在一定程度上限制了跨层语义信息的有效交互,导致浅层与深层特征之间存在语义脱节。此外,简单的逐层堆叠结构的融合过程较为粗糙,易造成有用信息被稀释或干扰。在对空间细节和上下文感知能力要求较高的车道线检测任务中,这种结构性缺陷更加明显。针对上述问题,本文在 ResNet 的不同残差层之间引入了门控融合模块(gated fusion module),用于动态融合当前层特征与前一层输出,提高车道线上下文信息交互的有效性。

门控融合模块如图3所示。该模块接受两个特征作为输入,分别是当前残差层输出 X_i 和上一残差层输出

征弱的问题,本文在 Resnet-18 中加入了门控融合模块将低层细节特征与高层语义特征融合。同时,门控融合模块能够动态调整每层信息的权重,使得网络能够适应多样化条件下的车道线检测。此外,为了更好地实现多尺度特征融合,在特征金字塔网络(FPN)中引入大核注意力用于增大感受野,增加上下文信息的获取,使得网络能够更好地获取图像中的含车道线信息。经过 FPN 融合后的特征输入到检测头、辅助分割中,以进行车道线检测。同时,为保证检测速度,辅助分割仅在训练时使用,推理时禁用。

X_{i-1} , 两个特征融合后输出的特征作为下一个残差层的输入。 X_{i-1} 经过下采样调整尺寸大小与 X_i 一致,随后两个特征使用 1×1 卷积统一通道数,确保可加性。然后,将两层特征相加后进行全局平均池化,再通过 1×1 卷积与 Sigmoid 函数生成门控权重,进而对两个输入进行加权融合。门控融合的输出如式(3)所示。

$$Out = W_{gate} \times f(X_{i-1}) + (1 - W_{gate}) \times f(X_i) \quad (3)$$

式中: W_{gate} 为门控权,如式(4)所示。

$$W_{gate} = \sigma(f(AvgP(f(X_{i-1}) + f(X_i)))) \quad (4)$$

式中: σ 表示 Sigmoid 函数; $f(\cdot)$ 表示卷积操作; $AvgP(\cdot)$ 表示全局平均池化。

改进后的 ResNet 通过引入门控机制,引导网络自适应地调节前一层特征信息的保留程度,有效抑制了冗余信息的传播。同时,该机制促进了浅层结构信息与深层语义特征之间的协同融合,从而增强了车道线边缘细节




图3 门控融合模块

Fig.3 Gated fusion module

的表达能力,提升了网络在车道线检测任务中的特征感知与定位精度。

1.4 大核注意力

在车道线检测任务中,车道线通常为细长、连续并且跨越大范围空间的结构,这对网络模型的感受野和多尺度感知能力提出了更高的要求。然而,传统 FPN 在处理这类车道线结构时仍存在局限性。一方面,FPN 使用较小的卷积核进行局部感知,导致难以捕捉远距离或连续结构的上下文信息;另一方面,其多尺度融合方式偏向粗糙拼接,缺乏更细致的尺度间特征交互,容易在复杂场景




图4 大核注意力

Fig.4 Large kernel attention

检测头模块以 FPN 输出的特征映射和车道先验作为输入。每个车道先验利用 ROIAlign^[16] 获得车道先验的 ROI 特征,使用双线性插值来计算这些位置在特征图上的精确值,再对提取到的车道线特征进行 9×9 的卷积操作,以获取车道线特征像素点附近的像素信息。然后,通过全连接操作进一步提取预设的车道线特征 ($X_p \in \mathbf{R}^{C \times 1}$)。同时,在检测头模块中还计算了车道先验与全局特征 ($X_f \in \mathbf{R}^{C \times H \times W}$) 之间的关系,首先对全局特征

下漏检或误检车道线。

针对上述问题,本文在 FPN 的横向连接中引入了大核注意力^[15],其结构如图4所示。大核注意力采用多个不同尺度的深度可分离卷积(如 DConv5×5、7×1、1×7、11×1、1×11、21×1、1×21)对输入特征进行方向性与尺度性建模。这种方式考虑到车道线在图像中的长度方向延展,显著扩大了空间感受野,能够同时捕捉到车道线的局部纹理细节与全局连续结构。同时,模块通过多尺度聚合路径对不同尺度卷积响应进行融合,并借助通道注意力机制对关键尺度信息的选择,这一机制有效提升了模型对不同尺度车道线的区分与响应能力。大核注意力处理后的输出表达式为:

$$Att = W_1 \left(\sum_{i=0}^3 Mutich_i(DConv_{5 \times 5}(X)) \right) \quad (5)$$

$$Out = Att \odot (W_2 X) + X \quad (6)$$

式中: X 为输入特征; W_1 、 W_2 为两个线性层; $Mutich_i$ 为多尺度特征的第 i 个连接结构; Att 为权重通道。

1.5 检测头

在实际道路场景中,车道线常受到光照变化、遮挡等因素的影响,导致其在图像中出现模糊、中断或不连续的现象。这种情况下,仅依赖局部的像素信息往往难以准确判断某一位置是否属于车道线。因此,网络模型需要综合周围区域的语义和上下文特征,做出更准确的判断。为此,本文利用多个尺度的检测头来进一步学习车道线的特征,实现车道线的分类和回归任务。

进行尺寸归一化操作,使其与 ROI 特征的尺寸相同,接着构建 ROI 特征与全局特征之间的注意力矩阵,从而捕捉局部候选区域与全局上下文之间的语义依赖。ROI 特征 X_p 与全局特征 X_f 之间的注意力矩阵计算公式如下:

$$W = f\left(\frac{X_p^T X_f}{\sqrt{C}}\right) \quad (7)$$

式中: f 是归一化函数 $softmax$; C 为特征图通道数。将注意力矩阵与全局特征图 X_f 相乘:

$$G = WX_f^T \quad (8)$$

其中, G 反映的是 X_f 对 X_p 的特征加成。最后, 再将输出 G 添加到 X_p 上, 得到下一层级的车道先验。

1.6 辅助分割分支

辅助分割分支与检测头共享主干网络和颈部网络的参数, 仅在训练阶段引入额外的像素级监督信号, 用于引导特征学习与参数优化。同时, 模型的最终车道线检测结果完全由检测头生成, 辅助分割分支不参与推理阶段的预测过程。因此, 推理阶段将该分支禁用不会对车道线检测性能及推理开销产生任何影响。

具体而言, 该辅助分割分支以 FPN 输出的 3 个不同尺度特征图作为输入, 通过特征拼接 (concatenation) 实现多尺度信息融合, 并采用三层卷积结构逐步完成通道压缩与特征整合, 生成像素级分割预测结果, 并与分割标签计算辅助分割损失。整体结构设计简洁, 其参数量仅为 0.15×10^{-6} , 相较于主干网络和检测头的参数规模, 该额外开销可以忽略不计。

CULane 数据集上, 辅助分割分支启用与禁用情况下的显存消耗与训练时长对比如图 5 所示, 引入辅助分割分支后, 训练阶段显存占用由 8 266 MB 增加至 8 780 MB, 额外显存开销约为 514 MB; 同时, 单个 epoch 的训练时长仅由 29 min 增至 30 min, 变化幅度较小。上述结果表明, 该辅助分割分支在训练阶段带来的额外计算开销是可控的。




图 5 辅助分割分支对训练成本的影响

Fig. 5 The impact of auxiliary segmentation branches on training cost

1.7 损失函数

基于以上改进, 本文网络模型的损失函数为:

$$L_{total} = w_{cls} L_{cls} + w_{xytl} L_{xytl} + w_{lIoU} L_{lIoU} + w_{seg} L_{seg} \quad (9)$$

式中: w_{cls} 、 w_{xytl} 、 w_{lIoU} 和 w_{seg} 为不同损失函数的权重超参数。Focal loss 用于区分车道先验是否为真实的车道线, 其计算公式如下:

$$L_{cls} = -\alpha_i (1 - p_i)^{\gamma} \log(p_i) \quad (10)$$

式中: α_i 是平衡正负样本的权重; p_i 是预测目标类别的概率; γ 是真实标签; γ 是聚焦参数, 用于调节容易分类样本的损失贡献。

Smooth L1 Loss 作为车道先验中起始点坐标、与 x 轴的夹角、车道线长度的回归损失, 用于约束车道线整体几何形态。计算公式如下:

$$L_{xytl} = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \quad (11)$$

Line IoU Loss 用于约束预测车道线与真实车道线在整体形状上的一致性。通过计算预测车道线与真实车道线之间的交并比来衡量两者之间的相似度, 从而优化网络模型, 其计算公式如下:

$$L_{lIoU} = 1 - \frac{\sum_{i=1}^N IL_i}{\sum_{i=1}^N UL_i} \quad (12)$$

式中: IL_i 表示两条车道线之间交集部分的长度; UL_i 表示两条车道线之间并集部分的长度。

辅助分割分支使用 Cross Entropy Loss 作为损失函数, Cross Entropy Loss 用于衡量模型输出的概率分布与真实标签的概率分布之间的差异, 有助于调整网络参数, 提升车道线检测的准确率, 其计算公式如下:

$$L_{seg} = -y \log(\hat{y}) - (1 - y) \log(1 - \hat{y}) \quad (13)$$

式中: y 是真实标签, 取值为 0 或 1; $\hat{y}$ 是模型预测的概率, 取值范围为 $[0, 1]$ 。

2 实验

2.1 数据集

为评估改进方法, 本文使用两个公开数据集 TuSimple 和 CULane 进行实验。TuSimple 是在稳定光照条件下采集的高速公路场景数据集, 数据集中共有 6 408 张图像, 其中训练集有 3 268 张图像, 测试集有 2 782 张图像, 验证集有 358 张图像, 图像分辨率为 $1\,280 \times 720$; CULane 数据集中包括了 9 种不同复杂场景, 数据集由 133 235 张图像组成, 其中训练集包含 88 880 张图像, 测试集包含 34 680 张图像, 验证集包含 9 675 张图像, 图像分辨率为 $1\,640 \times 590$ 。

2.2 实验环境及参数

本文实验在 NVIDIA 3090 GPU 上进行, 操作系统为 Ubuntu18.04, 使用 PyTorch 深度学习框架。TuSimple 数据集使用基础学习率为 0.001 的 AdamW 优化器, 训练 70 轮。CULane 数据集使用 AdamW 优化器, 基础学习率设置为 0.000 6, 训练 20 轮。

图像输入网络之前, 将所有图像的尺寸均调整为 320×800 , 对调整后的图像采用水平翻转、随机亮度、随机色调、随机饱和度、运动模糊、中值模糊和仿射变换实现图像增强。车道先验采样点数均设置为 72。权重超参

数 w_{cls} 、 w_{xyl} 、 w_{LloU} 和 w_{seg} , TuSimple 数据集中分为设置为 2.0、6.0、0.5、1.0, 在 CULane 数据集中分别设置为 2.0、2.0、0.2、1.0。权重设置差异是由于两个数据集差异较大, CULane 数据集更加复杂。Smooth L1 Loss 主要用于约束车道线的起始位置、方向角度以及长度参数, 对车道线整体几何形态的建模具有决定性作用。TuSimple 数据集场景相对规整、结构简单, 车道线几何形态清晰且稳定, 因此适当提高回归损失权重 ($w_{xyl} = 6.0$) 有助于强化几何约束, 从而提升检测精度。相比之下, CULane 数据集包含大量遮挡、复杂光照等情况, 车道线几何形态不完整且噪声较多, 过大的回归权重容易放大局部误差, 因此采用较为温和的权重设置 ($w_{xyl} = 2.0$) 更为合理。

2.3 评价指标

由于数据集差异, TuSimple 和 CULane 的官方评价指标不同。TuSimple 的官方评价指标为准确性 (Acc), 其计算公式如下:

$$Acc = \frac{\sum_{clip} C_{clip}}{\sum_{clip} S_{clip}} \tag{14}$$

式中: C_{clip} 表示正确预测的车道线点数量; S_{clip} 表示真实车道线点数量。对于 CULane 数据集, 官方评价指标为 F1 分数, F1 分数是精确率 (precision) 和召回率 (recall) 的调和平均, 其计算公式如下:

$$\begin{cases} F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \\ Precision = \frac{TP}{TP + FP} \\ Recall = \frac{TP}{TP + FN} \end{cases} \tag{15}$$

式中: TP 为真阳性; FP 为假阳性; FN 为假阴性。

2.4 实验结果

为评估模型性能, 本文在 TuSimple 和 CULane 两个公开数据集上与车道线检测领域中具有代表性的先进方法进行了对比实验。

在 TuSimple 数据集上的实验结果如表 1 所示。该数据集采集于稳定的光照条件下, 并且场景相对单一, 因此不同方法之间的准确率差异较小。在此数据集上, 本文方法取得了最高的准确率 (96.96%), 体现了其在标准条件下良好的检测性能。同时, FP 指标是表中最低的。这表明, 本文方法在保证高准确率的同时, 有效减少了误检, 进一步验证了其车道线检测的精度优势。与 CLNet-Res18 相比, 本文方法的 FN 略高。这主要是由于本文模型在设计上更加侧重于车道线的整体完整性与结构一致性, 在检测过程中对预测结果的判定更为严格。当面对局部纹理较弱或标注边界不清晰的车道线时, 模型倾向采取更加保守的预测策略, 从而在一定程度上导致 FN 指标的轻微上升。

表 1 TuSimple 数据集上的实验结果
Table 1 Experimental results on TuSimple dataset

方法	Acc	FP	FN
SCNN ^[6]	96.53	6.17	1.80
SGRNet ^[8]	95.7	3.39	2.71
CondLaneNet ^[11]	96.64	3.01	8.82
CLNet-Res18 ^[13]	96.64	2.28	1.92
LaneATT ^[17]	95.59	6.64	7.17
ResNet-34 ^[18]	95.23	6.40	6.22
BézierLaneNet ^[19]	95.87	5.00	3.40
MVTLane-S ^[20]	95.65	3.5	2.7
LSCoMer ^[21]	96.68	2.76	3.20
本文	96.96	1.96	2.24

在 CULane 数据集上的实验结果如表 2 所示。该数据集包含多种复杂场景, 其中 Cross 场景以 FP 作为评价指标, 其余 8 个场景均采用 F1 分数进行评估。由表 2 可见, 本文方法取得 80.1% 的 F1 分数, 高于表中所有对比方法, 并且在其中 7 个场景中表现最优。此外, 本文方法在帧率 (FPS) 方面也保持较高水平, 体现了良好的实时性。实验结果充分说明, 本文方法在复杂多变的环境下依然能够实现高精度的车道线检测。

表 2 CULane 数据集上的实验结果
Table 2 Experimental results on CULane dataset

方法	Normal	Crowded	Dazzle	Shadow	No-line	Arrow	Curve	Cross	Night	Total	FPS
SCNN ^[6]	90.6	69.7	58.5	66.9	43.4	84.1	64.4	1 990	66.1	71.6	25
CondLaneNet ^[11]	93.3	77.1	71.1	79.9	51.8	89.8	73.8	1 387	73.9	78.7	137
CLNet-Res18 ^[13]	91.8	76.9	71.1	80.6	53.4	87.8	68.9	1 404	73.8	78.9	119
ADNet ^[15]	92.9	77.4	71.7	79.1	52.9	80.9	70.6	1 499	74.7	78.9	62
LaneATT ^[17]	91.7	76.1	69.4	76.1	50.4	86.2	64.1	1 264	73.9	77.1	38
SGNet ^[22]	92.1	75.4	67.8	74.3	50.9	87.9	69.6	1 373	72.6	77.2	98
PINet ^[23]	90.3	72.3	66.3	68.4	49.8	83.7	65.2	1 427	67.7	74.4	25
IANet ^[24]	90.0	75.0	67.4	74.4	47.9	87.4	72.4	1 425	71.9	75.7	
本文	93.7	78.9	74.9	81.6	52.9	90.7	71.6	1 066	75.2	80.1	103

此外,为验证本文方法的工程应用指导价值,本文采用 FP16 半精度量化与结构化通道剪枝相结合的方式,对模型进行联合压缩。在量化过程中,将模型参数与推理计算精度由 FP32 转换为 FP16;剪枝策略采用基于通道重要性评估的结构化剪枝,以卷积层输出通道的 L1 范数作为重要性度量,对主干网络中的通道进行裁剪。在不引入任何训练或微调过程的前提下,对压缩后的模型进行推理评估。在 CULane 数据集上的实验结果如表 3 所

示。实验结果表明,尽管模型精度相较原始 FP32 模型存在一定下降,但整体性能仍保持在可接受范围内,同时模型的推理效率得到优化,验证了本文方法的工程应用潜力。

表 3 量化-剪枝实验
Table 3 Quantization-pruning experiment

模型	F1/%	FPS
原始模型	80.1	103
量化-剪枝	79.2	144




图 6 检测结果可视化
Fig. 6 Visualization of test results

2.5 消融实验

为验证本文所提出模块的有效性,在 CULane 数据集上进行了消融实验。

所有实验均采用相同的训练超参数,分别对不同模块进行组合与对比,以分析各模块对整体性能的影响。实验结果如表 4 所示,在基准模型的基础上,单独引入门控融合模块、大核注意力模块和辅助分割分

支后,模型的 F1 分数分别提升了 0.8%、0.7% 和 0.3%,表明各个模块对性能提升均具有积极作用。当同时引入上述 3 个模块时,模型的 F1 分数进一步提升,说明各模块之间具有良好的协同效果。上述结果充分验证了本文所提出模块在车道线检测任务中的有效性,表明所提出的模块有助于提升检测的准确性与鲁棒性。

表 4 消融实验
Table 4 Ablation experiment

基准模型	门控融合模块	大核注意力	辅助分割	F1/%
✓				78.9
✓	✓			79.7
✓		✓		79.6
✓			✓	79.2
✓	✓	✓		79.9
✓	✓	✓	✓	80.1

2.6 可视化结果

为了更直观地展示本文方法在车道线检测任务中的实际效果,本文在 CULane 数据集上对检测结果进行了可视化。如图 6 所示,可视化结果展示了本文方法在不同场景下的车道线检测效果。可以看出,本文方法在复杂场景中仍能够准确识别车道线的数量与空间位置,模型预测结果与真实标注高度吻合。在 No-line 场景中,箭头所指位置处 CLRNNet-18 检测到的车道线并不完整,存在漏检现象。而本文方法漏检现象减少,整体结构连续性与完整性更优。可视化结果表明,本文方法在整体检测性能优于对比方法。

3 结 论

为实现复杂场景下高精度的车道线检测,提出先验引导的多尺度车道线检测网络。本文提出的门控融合模块用于引导网络自适应地调节前一层特征信息的保留程度,从而有效抑制冗余信息在网络中的传播,提升了特征表达的质量;在 FPN 中引入大核注意力,有效扩大了网络的感受野,使网络能够更准确地感知车道线的全局结构;提出辅助分割分支,通过引入交叉熵损失辅助优化主干网络的训练过程,从而进一步提升了检测精度。实验表明,本文所提出的方法在两个数据集上均取得了优异的检测性能,在复杂路况下表现出更强的鲁棒性。未来的工作将进一步聚焦于模型的轻量化设计与推理速度的优化,以更好地满足实际道路场景中实时检测的需求。

参考文献

[1] 范晖,夏清国. 基于平行 Snake 耦合 Kalman 滤波器的车道线检测算法[J]. 电子测量与仪器学报,2019,33(2):101-109.
FAN H, XIA Q G. Lane line detection algorithm based on parallel Snake coupled Kalman filter [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (2): 101-109.

[2] XU D. Color-enhanced lane line detection algorithm based on HSL color space [C]. Third International Conference on Computer Graphics, Image, and

Virtualization (ICCGIV 2023). SPIE, 2023, 12934: 483-490.

[3] TABELINI L, BERRIEL R, PAIXÃO T M, et al. PolyLaneNet: Lane estimation via deep polynomial regression [C]. 2020 25th International Conference on Pattern Recognition (ICPR), 2020.

[4] QIN Z Q, WANG H Y, LI X. Ultra fast structure-aware deep lane detection [C]. Proceedings of the 16th European Conference on Computer Vision, 2020: 276-291.

[5] 李沐原,张兰春,哈瑞峰. 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.
LI M Y, ZHANG L CH, HA R F. Lane detection method based on multi-scale dilated fusion attention [J]. Electronic Measurement Technology, 2024,47 (23): 84-92.

[6] PAN X G, SHI J P, LUO P, et al. Spatial as deep: Spatial CNN for traffic scene understanding [C]. Proceedings of the Thirty Second AAAI Conference on Artificial Intelligence, 2018: 891.

[7] ZHENG T, FANG H, ZHANG Y, et al. Resa: Recurrent feature-shift aggregator for lane detection[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(4): 3547-3554.

[8] 潘玉恒,刘泽帅,鲁维佳,等. 基于生成式对抗网络与 ResNeXt 的车道线检测算法[J]. 公路交通科技,2024, 41(12):39-47.
PAN Y H, LIU Z SH, LU W J, et al. Traffic line detection algorithm based on generative adversarial networks and ResNeXt [J]. Journal of Highway and Transportation Research and Development, 2024, 41(12): 39-47.

[9] NEVEN D, DE BRABANDERE B, GEORGOULIS S, et al. Towards end-to-end lane detection: An instance segmentation approach [C]. 2018 IEEE Intelligent Vehicles Symposium, 2018: 286-291.

[10] 蒯晓,丁飞,张登银. 多分支融合注意力机制的车道线检测模型[J]. 电子测量与仪器学报, 2023, 37(4): 35-43.
KUAI X, DING F, ZHANG D Y. Lane detection algorithm based on edge information coupling improved Hough transforms[J]. Journal of Electronic Measurement and Instrumentation, 2023,37(4): 35-43.

[11] LIU L, CHEN X, ZHU S, et al. CondLaneNet: A top-to-down lane detection framework based on conditional convolution [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021:

- 3773-3782.
- [12] HOU Y N, MA Z, LIU C X, et al. Learning lightweight lane detection CNNs by self-attention distillation [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1013-1021.
- [13] ZHENG T, HUANG Y F, LIU Y, et al. CLNet: Cross layer refinement network for lane detection [C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA. IEEE, 2022: 888-897.
- [14] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936-944.
- [15] XIAO L Y, LI X, YANG S, et al. ADNet: Lane shape prediction via anchor decomposition [C]. 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France. IEEE, 2023: 6381-6390.
- [16] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu: IEEE, 2017: 1132-1140.
- [17] TABELINI L, BERRIEL R, PAIXAO 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 (CVPR), 2021.
- [18] FENG Z, GUO S, TAN X, et al. Rethinking efficient lane detection via curve modeling [C]. Proc of IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2022: 17062-17070.
- [19] WU Y J, ZHAO L Q, LU J W, et al. Dense hybrid proposal modulation for lane detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(11): 6845-6859.
- [20] 陈广秋, 刘枫铭, 段锦, 等. 基于轻量化 Transformer 的车道线检测方法 [J]. 华中科技大学学报 (自然科学版), 2025, 53(3): 117-126.
- CHEN G Q, LIU F M, DUAN J, et al. Lane line detection method based on lightweight transformer [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2025, 53(3): 117-126.
- [21] 郑剑, 郭亦畅. 基于 LSTR 和 ViT-CoMer 骨干的车道线检测方法 [J]. 电子测量技术, 2024, 47(19): 164-171.
- ZHENG J, GUO Y CH. Lane detection method based on LSTR and ViT-CoMer [J]. Electronic Measurement Technology, 2024, 47(19): 167-171.
- [22] SU J M, CHEN C, ZHANG K, et al. Structure guided lane detection [C]. Proceedings of the International Joint Conference on Artificial Intelligence. Sacramento: IJCAI, 2021: 997-1003.
- [23] 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.
- [24] 姜彦吉, 张颖阳, 董浩, 等. 基于实例关联的暗光下车道线检测 [J]. 系统仿真学报, 2025, 37(9): 2188-2199.
- JIANG Y J, ZHANG Y Y, DONG H, et al. Lane detection in dark light based on instance association [J]. Journal of System Simulation, 2025, 37(9): 2188-2199.

作者简介



张全, 2007 年于西南石油大学获得学士学位, 2011 年于湘潭大学获得硕士学位, 2015 年于电子科技大学获得博士学位, 现为西南石油大学副教授, 主要研究方向为计算机视觉、图像处理、并行计算。

E-mail: zhangquan@swpu.edu.cn

Zhang Quan received his B. Sc. degree from Southwest Petroleum University in 2007, M. Sc. degree from Xiangtan University in 2011, and Ph. D. degree from University of Electronic Science and Technology of China in 2015, respectively. Now he is an associate professor in Southwest Petroleum University. His main research interests include computer vision, image processing, and parallel computing.



刘洋毅 (通信作者), 2012 年于重庆大学获得学士学位, 2016 年于中国科学院大学获得博士学位, 现为四川警察学院和智能警务四川省重点实验室副教授, 主要研究方向为计算机视觉、智能交通。

E-mail: liuyangyi_ioe@163.com

Liu Yangyi (Corresponding author) received his B. Sc. degree from Chongqing University in 2012, and Ph. D. degree from University of Chinese Academy of Sciences in 2016, respectively. Now he is an associate professor in Sichuan Police College and Intelligent Policing Key Laboratory of Sichuan Province. His main research interests include computer vision and intelligent transportation.