

基于双分支分解卷积的夜间车道线检测方法

张 绪, 林玉娥, 王 慧, 梁兴柱

安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001

摘要:目的 车道线检测作为自动驾驶系统的核心功能之一,对于确保车辆安全行驶至关重要。然而,当前基于分割的检测方法在速度和性能之间存在明显不平衡,尤其在夜间场景下更为突出。针对这一挑战,提出一种名为 DecoLaneNet 的夜间车道线检测模型。**方法** 首先,设计一种高效的特征提取模块,采用分解卷积构建具有不同大小感受野的双分支分解卷积残差结构,在尽可能保证性能的情况下大幅减少模型的参数量,更准确地提取车道线特征;接着,运用通道重排技术和扩张卷积弥补性能损失,并增加感受野;最后,引入双分支上采样模块进行特征解码,显著提升了模型的分割精度。**结果** 在夜间场景数据集 Night 和包含多种交通场景的车道检测数据集 CULane 上进行了广泛评估,DecoLaneNet 的 F_1 评分,在 Night 数据集上达到了 74.7%,在 CULane 数据集上达到了 71.5%。值得一提的是,尽管模型参数仅有 1.94 M,但在 Jetson 开发板上,其帧率(FPS)仍能达到 62.5。**结论** 实验结果表明,DecoLaneNet 不仅在夜间场景下表现出优异的性能,在应对其他复杂场景时同样表现出色。此外,在部署到嵌入式设备上时,其性能与效率仍然优于其他模型,显示出了出色的潜力与可行性。

关键词: 车道线检测;通道重排;分解卷积;模型部署

中图分类号:U463.6;TP391.41 文献标识码:A doi:10.16055/j.issn.1672-058X.2026.0002.016

Nighttime Lane Detection Method Based on Dual-branch Decomposed Convolution

ZHANG Xu, LIN Yu'e, WANG Hui, LIANG Xingzhu

School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective Lane line detection, as one of the core functions of autonomous driving systems, is crucial for ensuring the safe driving of vehicles. However, current segmentation-based detection methods show a significant imbalance between speed and performance, which is particularly prominent in nighttime scenarios. To address this challenge, this paper proposes a nighttime lane line detection model called DecoLaneNet. **Methods** First, an efficient feature extraction module was designed. In this module, a dual-branch decomposed convolution residual structure with different-sized receptive fields was constructed using decomposed convolutions, which significantly reduced the number of model parameters while ensuring performance as much as possible and more accurately extracted lane line features. Then, channel rearrangement technology and dilated convolutions were used to make up for performance losses and increase the receptive field. Finally, a dual-branch upsampling module was introduced for feature decoding, which significantly improved the model's segmentation accuracy. **Results** Extensive evaluations were conducted on the nighttime scenario

收稿日期:2024-05-10 修回日期:2024-08-18 文章编号:1672-058X(2026)02-0125-08

基金项目:安徽理工大学环境友好材料与职业健康研究院研发专项基金项目资助(ALW2021YF04);安徽理工大学医学专项培育项目资助(YZ2023H2C005);安徽理工大学研究生创新基金项目资助(2023CX2129)。

作者简介:张绪(2000—),男,安徽亳州人,硕士研究生,从事计算机视觉与车道线检测等研究。

通信作者:林玉娥(1979—),女,黑龙江宁安人,博士,副教授,从事计算机视觉、模式识别等研究。Email:yelin@aust.edu.cn

引用格式:张绪,林玉娥,王慧,等.基于双分支分解卷积的夜间车道线检测方法[J].重庆工商大学学报(自然科学版),2026,43(2):125-132.

ZHANG Xu, LIN Yu'e, WANG Hui, et al. Nighttime lane detection method based on dual-branch decomposed convolution[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 125-132.

dataset Night and the lane detection dataset CULane containing various traffic scenarios. The F_1 score of DecoLaneNet reached 74.7% on the Night dataset and 71.5% on the CULane dataset. Remarkably, despite having only 1.94 M parameters, the model maintained a speed of 62.5 FPS on the Jetson development board. **Conclusion** The experimental results show that DecoLaneNet not only performs excellently in nighttime scenarios but also shows good performance in dealing with other complex scenarios. Moreover, when the model is deployed on embedded devices, its performance and efficiency are still better than those of other models, showing excellent potential and feasibility.

Keywords: lane detection; channel shuffle; decomposed convolution; model deployment

高级驾驶辅助系统(ADAS)是自动驾驶技术的关键组成部分,受益于深度学习技术,它可以在各种驾驶场景中为驾驶员提供帮助。在 ADAS 中,车道线检测是确保车辆稳定行驶的重要保障。然而,在夜间环境下,受多种光源和其他车辆影响,车道线检测的难度进一步增加。一个准确的车道线检测系统能够及时发现车道线,并提供警告和辅助,帮助驾驶员保持在正确的车道上行驶,从而避免偏离或碰撞。因此,对于夜间驾驶来说,车道线检测系统至关重要,也是实现智能化驾驶的关键一步。

车道线检测方法可分为基于图像处理的传统方法^[1-2]和基于深度学习的方法^[3-12]。在夜间行驶中,受低光照、车道线磨损和车辆遮挡等因素影响,车道线的可见性降低,使得夜间车道线检测任务难度大大增加。传统方法首先对夜间图像进行光照增强,接着进行图像预处理、特征提取和车道线拟合。然而,这类方法往往需要人工手动调整滤波器算子和参数,工作量大,并且泛化能力较差。相较之下,基于深度学习的方法^[9-13]具有自动提取图像特征、泛化能力强和应用场景广等优势,开始成为车道线检测任务的主流方法。

基于深度学习的方法可分为 3 类:基于锚点检测^[3-5]、基于参数拟合^[6-8]和基于分割^[9-12]的方法。在基于锚点检测的方法中,Qin 等^[3-4]采用一种简单快速的方法,通过预测车道的位置信息,并利用轻量级主干网络进行高速推理。尽管该方法速度快,但整体性能并不突出。相比之下,Liu 等^[5]提出一种更为复杂的策略,它利用条件卷积和行锚点来定位车道线的起始点,然后执行基于行锚点的车道检测。然而,在某些复杂场景下,这种方法可能会遇到起始点识别困难的问题,从而导致性能相对较差。在基于参数拟合的方法中,Tabelini 等^[6]利用多项式回归拟合车道线,提高了车道线检测的效率。相较之下,Liu 等^[7]考虑道路结构和摄像机姿态,通过 Transformer 获取全局特征,并以此对车道形状进行建模;Feng 等^[8]引入 Bezier 曲线,进一步提升了检测精度。尽管这类方法的参数量较少,但它们

对预测参数的敏感性较高,即使微小误差也可能显著影响车道形状。虽然这些方法推理速度快,但要实现更高水平的性能仍然具有挑战性。在基于分割的方法中,Neven 等^[9]将车道线检测视为实例分割任务,通过端到端的网络架构,实现对各种数量车道线的有效检测;Hou 等^[10]允许模型通过自蒸馏来提高性能,无须额外的监督或标签,并且具有较低的参数量和较高的推理速度,然而,往往难以达到更高的性能水平。Pan 等^[11]提出一种消息传递机制,以捕获车道的空间关系,从而显著提高检测性能,然而,由于速度较慢,并不适用于实时应用。相较之下,Zheng 等^[12]提出实时特征聚合模块,有助于网络获取全局特征并提高性能。尽管这些方法在解决车道线检测任务中取得了一定进展,但它们仍然存在速度、性能和实时应用方面的一些限制,特别是在夜间场景下这些限制更加明显。

为解决上述问题,本文提出一种名为 DecoLaneNet 的车道线检测方法,通过改进基础残差模块来实现模型性能和速度的平衡。首先,在特征编码阶段,DecoLaneNet 利用分解卷积思想,设计了一种多尺度双分支残差结构,这一设计有效整合了不同大小的感受野,从而显著提升了骨干网络的特征提取能力,同时大幅减少了模型的参数量和推理时间。其次,采用双分支采样模块来改进上、下采样过程,进一步增强了模型的性能,实现了更为精细化的分割结果。为了满足工程需求并降低能耗,本文将设计的夜间车道线检测模型部署到嵌入式设备上,以最小的代价推动模型的运行。

1 方法的提出

1.1 网络结构

DecoLaneNet 网络结构如图 1 所示,模型主体部分采用常见的基于 Encoder-Decoder^[11-12]架构的分割网络。其中,在编码器中,将传统的残差结构替换为新提出的带有扩张卷积的混洗分解卷积残差模块(SDCRM-DC)。同时,改进上、下采样模块,将其替换为双分支采样模块。为了确保模型在较浅的隐藏层也能学到深层语义信息,引入辅助分割网络(Aux)。具体来说,在解

码器中 Decoder1 和 Decoder2 阶段通过简单的线性插值将特征图上采样至原图大小,以提升模型的分割性能。

辅助分割模块仅存在于训练阶段,在测试阶段被移除,不会增加模型的推理时间。

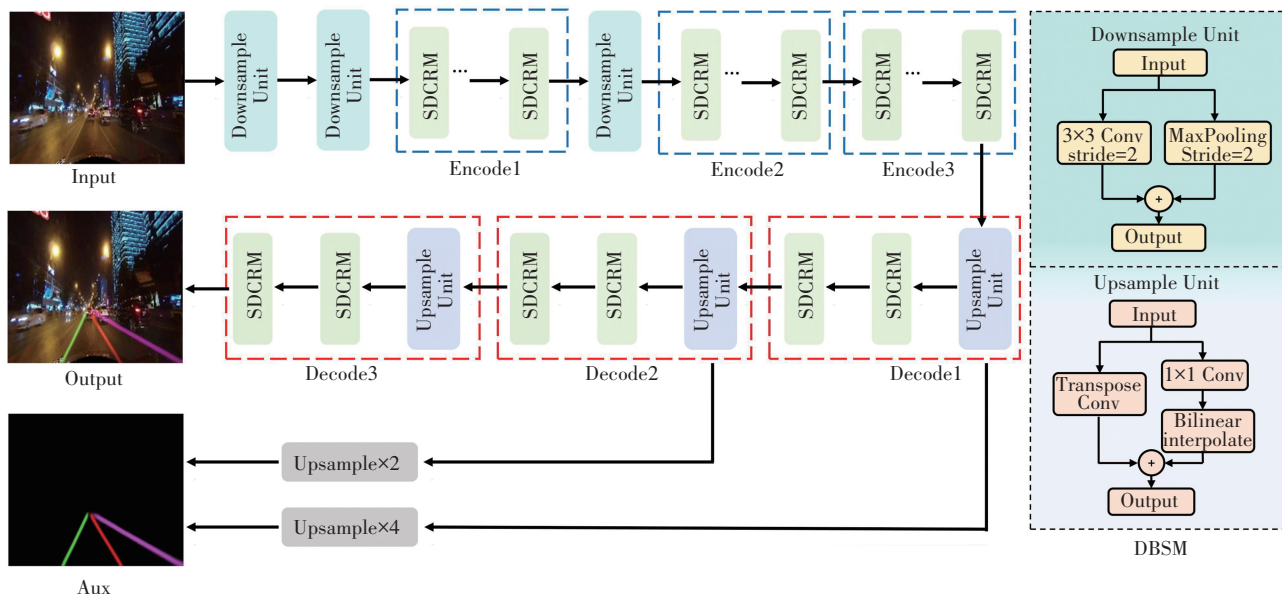


图 1 DecoLaneNet 网络结构图

Fig. 1 DecoLaneNet network architecture diagram

1.2 SDCRM-DC 模块

残差网络 ResNet^[14] 的提出为许多视觉任务带来了性能提升,使得训练更深层次的神经网络成为可能。然而,对于夜间车道线检测等特定任务来说,并不是简单地增加网络深度就能实现最佳性能。这是因为车道线像素通常只占原始图像的一小部分,并且分布范围很广。此外,过多的激活函数设置可能会导致网络在前向传播中丢失关键车道线特征,进而影响模型性能,并且网络过深也会带来梯度消失和梯度爆炸等问题。因此,过深的网络不仅无法提升性能,反而可能会导致性能下降。

除了考虑网络深度,也要关注网络宽度^[15],即通道数,因为它对性能也有重要影响。增加网络宽度有助于缓解深层网络面临的梯度消失和梯度爆炸问题,并且可以提取更丰富的特征。然而,增加网络宽度会带来昂贵的代价,包括增加模型的参数数量和内存占用,以及降低模型的推理速度。对于夜间车道线检测任务来说,这样的代价尤为致命。因此,本文通过引入通道重排技术,从网络容量的角度出发,平衡深度和宽度,尽可能提升网络的表达能力。

除了网络自身限制之外,在夜间场景下,光照不均匀和遮挡同样增加了车道线特征提取的难度,因此需要具有更大感受野的网络设计。常用的 3 * 3 卷积已经无法满足需求,如图 2(a)所示,而过大的卷积核则会显著降低模型的推理速度。为了解决这一问题,本文设计了基于串行 3 * 3 和 5 * 5 卷积的基础残差模块,如

图 2(b)所示,用于提取车道线特征。考虑到二维卷积的计算开销较大,本文利用分解卷积思想,将其分解为 4 个一维卷积:3 * 1、1 * 3、5 * 1、1 * 5。这种策略不仅降低了模型参数量,还提高了推理速度,但可能会导致模型性能下降。为了弥补性能损失,同时引入 Channel shuffle 操作,提出混洗分解卷积残差模块 (SDCRM)。此外,为了进一步提升感受野,还引入扩张卷积^[16],将新提出的残存模块命名为 SDCRM-DC,如图 2(c)所示。

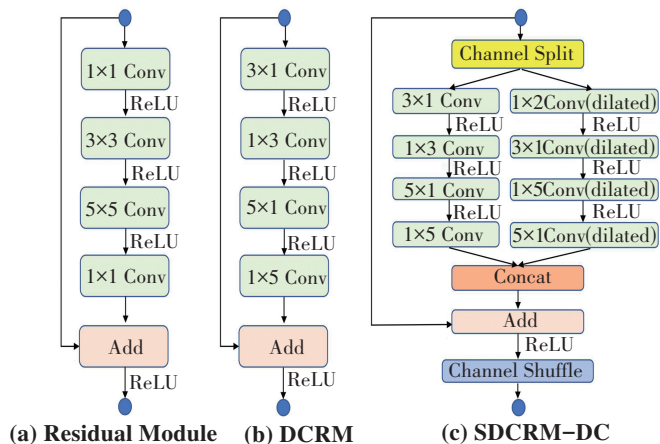


图 2 残差模块结构

Fig. 2 Residual module structure

分解卷积具有降低参数量和计算量的特点。不考虑卷积偏置时, $k * k$ 的标准二维卷积参数量 P 为

$$P = C_{out} * k^2 * C_{in} \quad (1)$$

式(1)中, C_{in} 、 C_{out} 分别为输入、输出特征图的通道数。

标准二维卷积计算量 F 参考浮点运算数 (Floating Point Operations, FLOPs) 计算公式:

$$F = C_{out} * (2 * k^2 * C_{in} - 1) * H_{out} * W_{out} \quad (2)$$

式(2)中, H_{out} 、 W_{out} 分别为输出特征图的高和宽。

卷积的参数数量和计算量与卷积核尺寸 k 呈 2 次方关系。将一个 $k * k$ 的二维卷积替换成 $k * 1$ 和 $1 * k$ 的分解卷积后,其参数数量和计算量与卷积核尺寸 k 呈线性关系:

$$P_f = 2 * k * C_{out} * C_{in} \quad (3)$$

$$F_f = [C_{out} * (2 * k * C_{in} - 1) * H_{out} * W_{out}] * 2 \quad (4)$$

式(4)中, P_f 为分解卷积参数数量, F_f 为分解卷积的计算量。综合式(1)~式(4)可知,卷积核的尺寸越大,分解卷积替代普通卷积的参数数量和计算量降低效果越明显。

1.3 双分支采样模块

在分割任务中,上采样和下采样是不可缺少的组成部分。下采样通常用于降低图像的分辨率,以减少计算复杂度,并使模型能够处理更大尺寸的输入图像。这有助于模型在更广泛的上下文中理解图像,并提取更高级别的语义特征。然而,下采样也会损失图像的细节信息,因此需要使用上采样来恢复这些细节并提高分割的精度。上采样一般通过线性插值或反卷积等方法将特征图的尺寸增加到原始图像的尺寸,从而帮助模型准确地定位和分割目标对象。

在本文的夜间车道线检测方法中,引入了双分支采样模块(Double-Branch Sampling Module, DBSM),其计算过程如下所示:

$$Y_{down} = \text{Cat}[f_{3 \times 3}(X), f_{MP}(X)] \quad (5)$$

$$Y_{up} = \text{Cat}[f_{BI}(f_{1 \times 1}(X)), f_{TCconv}(X)] \quad (6)$$

式(5)、式(6)中, X 和 Y 分别为输入特征和输出特征; $f_{3 \times 3}$ 表示一个卷积核大小为 $3 * 3$,步距为 2 的卷积层; $f_{1 \times 1}$ 表示一个卷积核大小为 $1 * 1$,步距为 1 的卷积层; f_{MP} 表示步距为 2 的最大池化层; f_{TCconv} 表示转置卷积; f_{BI} 表示双线性插值过程; Cat 表示向量拼接。

双分支采样模块旨在进一步增强模型的性能。在上采样阶段,双分支结构有效恢复了特征图的空间信息,从而提高了对细节信息的保留和还原能力。而在下采样阶段,双分支结构能够更好地捕获特征图的全局信息,有助于提高特征图的语义表示能力。这种双分支设计的采样模块不仅有效提升了模型性能,而且在保持模型轻量级的同时满足了实际工程应用的需求。

1.4 损失函数

车道线检测是对车道线和道路背景进行二分类的问题。交叉熵损失函数用于衡量分类问题中预测分布与真实分布之间的差异,它对概率分布的差异极为敏

感,有助于模型更准确地学习分类边界。因此,本文采用二分类交叉熵损失函数作为约束条件,其分割损失表达式如下所示:

$$L_{seg} = L_{CE}(S_{pred}, S_{gt}) \quad (7)$$

式(7)中, S_{pred} 为模型的预测值, S_{gt} 为真实标签, L_{CE} 为二分类交叉熵损失函数。

此外还加入了辅助分割损失用于提升模型的性能,其公式如下所示:

$$L_{aux} = \alpha L_{CE}(S_{aux1}, S_{gt}) + \beta L_{CE}(S_{aux2}, S_{gt}) \quad (8)$$

式(8)中, S_{aux1} 和 S_{aux2} 分别为图 1 中的 Decoder1 和 Decoder2 的预测值,其中 α 和 β 分别为该阶段的权重系数,取值在 0~1 之间。考虑到这两个额外辅助分割分支的存在是为了给予模型更多的信息,从而更好地学习分割边界,本文令 $\alpha + \beta = 1$,以确保这些辅助分支不会对模型产生过度影响,避免最终性能的下降。

最终车道线检测模型的总损失公式如下所示:

$$L_{total} = L_{seg} + L_{aux} \quad (9)$$

2 仿真实验与结果分析

2.1 数据集与评价指标

本研究在模型训练和评估过程中使用了两个数据集。首先,使用常用的 CULane 数据集,该数据集包含各种道路场景的图像以及对应的车道线标注信息。然而,注意到 CULane 数据集中夜间场景的比例相对较低,因此从中挑选出夜间场景数据,形成一个名为 Night 的子集。

Night 子集的选择覆盖了城市道路、乡村小径和高速公路等多种夜间场景,以确保数据集的多样性和代表性。使用 CULane 和 Night 数据集,旨在训练一个能够在不同场景下准确检测车道线的模型,并提高其在夜间场景下的性能表现。CULane 和 Night 车道线数据集的基本信息如表 1 所示。

表 1 CULane 和 Night 数据集的基本信息
Table 1 Basic information of the CULane and Night datasets

Dataset	Frame	Train	Test	Resolution
Night	8 500	6 090	2 410	800×288
CULane	123 560	88 880	34 680	1 640×590

根据文献[11-12]中的评估度量, Night 和 CULane 数据集将车道线视为 30 个像素宽的连续线段,然后通过计算预测结果与真实标签之间的交并比 (IoU) 来获取 F_1 分数,其计算公式为

$$\zeta_{precision} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (10)$$

$$\zeta_{recall} = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (11)$$

$$F_1 = \frac{2 \times \zeta_{\text{precision}} \times \zeta_{\text{recall}}}{\zeta_{\text{precision}} + \zeta_{\text{recall}}} \quad (12)$$

式(10)、式(11)中, N_{TP} 表示模型预测值与真实标签的 $\text{IoU} > 0.5$, N_{FP} 表示模型预测值与真实标签的 $\text{IoU} \leq 0.5$, N_{FN} 表示预测的车道线不存在。

2.2 实验环境设置

本文实验在 Ubuntu 22.04 系统下,基于 PyTorch 1.7.1 框架进行。对于 CULane 数据集,表 3 中的所有检测结果均来源于相应文献。而在 Night 数据集上,表 2 中的所有结果均在 GeForce RTX 3070Ti GPU 上重新训练得到,并且采用的训练策略以及实验设置保持

一致。

训练时,所有模型均采用随机梯度下降(Stochastic Gradient Descent,SGD)作为优化器,初始学习率设为 0.01,动量参数设为 0.9,权重衰减参数设为 10^{-4} ,采用 ReduceLRonPlateau 学习率下降策略,在 Night 和 CULane 上的训练轮次分别设置为 120 和 45,训练批次大小均设置为 8,式(8)中的 α 和 β 分别设置为 0.3 和 0.7。

2.3 实验结果及分析

本文展示了在 Night 和 CULane 两个数据集上的检测性能,并将 DecoLaneNet 与其他模型进行对比。结果如表 2、表 3 所示。

表 2 DecoLaneNet 与其他模型在 Night 数据集上的性能对比

Table 2 Performance comparison between DecoLaneNet and other models on the Night dataset

Method	Source	F_1 -measure/%	IoU/%	Precision/%	Recall/%	Params/M
SCNN ^[11]	AAAI 2018	71.72	58.28	68.19	75.69	19.78
ESPNetV2 ^[17]	CVPR 2019	64.97	51.29	63.89	66.19	1.19
R18-Ultra ^[3]	ECCV 2020	72.46	—	72.44	72.48	42.46
STDC2 ^[18]	CVPR 2021	68.09	54.27	63.02	74.14	15.33
R18-RESA ^[12]	AAAI 2021	69.2	55.6	65.44	73.51	13.2
ESA-official ^[19]	WACV 2022	73.96	60.92	75.05	72.95	13.57
DDRNet39 ^[20]	TITS 2022	67.21	53.51	64.66	70.08	29.14
LETNet ^[21]	TITS2023	71.07	57.78	66.32	76.74	0.91
MLP-Net ^[22]	TVT 2023	72.44	59.47	68.38	72.44	3.35
Ours	—	74.7	62.24	70.88	79.09	1.94

表 3 DecoLaneNet 与其他模型在 CULane 数据集上的性能对比

Table 3 Performance comparison between DecoLaneNet and other models on the CULane dataset

Category	Ours	RSCM ^[23]	AMSC ^[24]	R18-Ultra ^[3]	R18-E2E ^[25]	MLP-Net ^[22]	R18-SAD ^[10]
Normal/%	90.6	85.2	86.8	87.7	90.0	89.6	89.8
Crowded/%	70.3	63.8	64.5	66.0	69.7	67.1	68.1
Night/%	65.2	58.3	59.8	62.1	63.3	61.9	64.2
No line/%	44.0	43.9	38.4	40.2	43.2	41.8	42.5
Shadow/%	63.2	57.1	60.0	62.8	62.5	60.3	67.5
Arrow/%	85.6	77.8	77.4	81.0	83.2	83.0	83.9
Dazzle/%	61.9	56.6	55.7	58.4	60.2	59.9	59.8
Curve/%	64.1	57.0	63.4	57.9	70.3	61.4	65.5
Crossroad/%	2 640	2 107	2 358	1 743	2 296	2 071	1 995
Total/%	71.5	66.8	66.6	68.4	70.8	69.5	70.5
FLOPs/G	9.34	23.6	—	8.4	—	7.22	—
Params/M	1.94	3.21	20.7	42.46	—	3.17	12.41

从表 2 可以看出,本文提出的检测模型 DecoLaneNet 在夜间数据集 Night 上获得了优异的性能,各项指标均

表现最优。其中 IoU、 F_1 -measure、Precision 和 Recall 分别达到了 62.24%、74.7%、70.88% 和 79.09%。此外,模型还拥有较小的参数数量(仅为 1.94 M),可见 DecoLaneNet 模型在夜间场景下能够准确检测出车道线,并且具有更高的效率。

表 3 显示了不同模型在 CULane 测试集上的检测性能。结果表明,DecoLaneNet 在正常、拥挤、夜间、无车道线、道路箭头、炫光等 6 个场景中获得了最好的 F_1 -measure,分别为 90.6%、70.3%、65.2%、44.0%、85.6% 和 61.9%,在阴影、转弯、交叉路口 3 个场景中也获得了较优秀的 F_1 -measure。可见,本文提出的模型不仅在夜间场景中表现出色,而且在其他场景中也具有良好的检测性能。

2.4 消融实验

为了验证所提出方法的有效性,本研究在 Night 数据集上进行详细的消融实验。表 4 展示了各个模块的评估结果。首先,从 SDCRM 模块中移除 Channel shuffle,并采用 Concat 拼接方式,得到分解卷积残差模块(Decomposed Convolutional Residual Module,DCRM)。按照图 1 中的堆叠方式构建分割网络,并采用常规的双线性插值上采样作为解码器,最终实现了 66.71% 的 F_1 指标。随后,实验采用 SDCRM 模块构建网络, F_1 指标提升至 68.57%。在引入扩张卷积后,使用 SDCRM-DC 模块构建网络, F_1 指标进一步提高至 71.69%。这表明本文提出的残差模块具有更强的特征提取能力。前 3

列均是使用基础残差模块进行堆叠,第 4、第 5 列则是分别加入双分支采样模块和辅助分割分支模块,最终 F_1 指标分别达到了 72.5% 和 74.7%。可见本文提出的各个模块对模型均产生了正面影响,验证了所提模块的有效性。

表 4 各个模块的性能对比

Table 4 Performance comparison of each module

DCRM	SDCRM	SDCRM-DC	DBSM	Aux	F_1 -measure/%
✓					66.71
	✓				68.57
		✓			71.69
		✓	✓		72.5
		✓	✓	✓	74.7

2.5 定性分析

本文选择一些具有代表性的方法在 Night 数据集上进行定性分析。图 3 展示了 DecoLaneNet 模型与其他先进方法的结果对比。可以观察到,在夜间场景中,图像光亮度低且遮挡严重,现有方法无法保持车道线的平滑性和连续性。这是因为这些方法^[11,17,20]大多只关注局部信息而忽视全局信息的重要性。相比之下,DecoLaneNet 可以通过 SPA 模块整合模型提取到的局部信息和全局信息,在遮挡情况下准确预测出完整的车道线,这表明该方法具有更强的捕获车道整体结构和精细化边缘的能力。




图 3 模型检测结果可视化

Fig. 3 Visualization of model detection results

此外,为了更好地分析模型的效果,本文通过热力图可视化 ESPNetV2^[17]、RESA^[12]、DDRNet^[20] 和提出的 DecoLaneNet 模型的最后一层特征,如图 4 所示。可以

发现,本文模型不仅可以精准提取车道的各种细节信息,还能有效抑制背景干扰,这使得该方法能够在夜间场景下获得更高的检测精度。




图 4 热力图可视化

Fig. 4 Heatmap visualization

2.6 模型部署

夜间车道线检测对于降低夜间行车事故风险,确保驾驶人员和乘客的安全至关重要。然而,除了在理论层面满足任务需求外,将模型实际部署并使其在真实道路环境中稳定运行,也是评估其优劣的关键标准。

Jetson Orin NX 是 Nvidia 推出的低功耗人工智能嵌入式开发板,功耗为 25 W,浮点性能为 100TFLOPs,搭载了 1 024 核 Ampere GPU。本文最终将 Jetson Orin NX 搭载在车辆上进行实地检测,具体设备如图 5 所示。



图 5 设备实物图

Fig. 5 Physical diagram of the device

为了确保模型在不依赖于 PyTorch 框架的情况下能够独立运行,采取了一系列步骤。首先,将已训练的 PyTorch 模型权重文件转换为 ONNX (Open Neural Network Exchange) 格式。这样做的目的是为了实现在跨平台的模型交换和互操作性。接着,利用 TensorRT 对模型进一步优化。TensorRT 是一种高性能深度学习推理优化器,能够针对特定硬件平台和应用需求对模型进行优化。优化过程包括层融合、精度调整、内存优化和并行加速等步骤,以提高推理速度并降低功耗。这样做可以使模型更适用于嵌入式设备和实际应用场景,进一步提升模型的性能和适用性。

根据表 5 可以看出,DecoLaneNet 模型在部署方面相比其他模型具有明显的优势。为了进一步验证部署后模型的实际检测效果,将设备搭载到车辆上进行实地测试,结果如图 6 所示。可以看出本文提出的模型在夜间场景下不仅在部署速度上占据优势,在检测效果方面也优于其他模型。

表 5 模型部署后 FPS 对比

Table 5 FPS comparison after model deployment

Method	FPS (ONNX)	FPS (TensorRT)	Params/M
SCNN	0.72	26.31	19.78
RESA	1.01	40.00	13.2
ESPNetV2	3.35	47.61	1.19
Ours	4.30	62.50	1.94




图 6 模型部署后检测结果可视化

Fig. 6 Visualization of detection results after model deployment

3 结论与展望

本文针对夜间场景下的车道线检测任务,提出一种高效的检测 DecoLaneNet。通过运用分解卷积的思想对普通残差模块进行改进,并引入 Channel shuffle 和扩张卷积技术,进一步增强残差模块对车道线特征的提取能力。实验证明:本文设计的残差模块在处理夜间等复杂场景时表现出更强的特征提取能力,同时在保持性能的前提下,模型的参数量也得到了有效控制,仅为 1.94 M。在 Night 数据集上,DecoLaneNet 超过了其他模型,在各项指标上均表现优异。其中,IoU、 F_1 -measure、Precision 和 Recall 分别达到了 62.24%、74.7%、70.88% 和 79.09%。

未来的工作将着重于模型压缩和模型部署,以确保夜间车道线检测模型能够得到进一步优化,并成功应用于实际场景。此外,还将继续收集夜间场景下的各种道路图像,完善夜间车道数据集,使模型能够应对更多更复杂的环境。

参考文献(References):

[1] MA H, LYU W, LI Y, et al. Image adaptive contrast enhancement for low-illumination lane lines based on improved retinex and guided filter[J]. Applied Artificial Intelligence, 2021, 35(15): 1970-1989.

[2] 胡昊东, 刘贵如, 王陆林, 等. 一种基于消失点和颜色过滤器的车道线检测算法[J]. 重庆工商大学学报(自然科学版), 2023, 40(5): 25-33.

HU Hao-dong, LIU Gui-ru, WANG Lu-lin, et al. A lane detection algorithm based on vanishing point and color filter[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(5): 25-33.

- [3] QIN Z, WANG H, LI X. Ultra fast structure-aware deep lane detection [M]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 276–291.
- [4] QIN Z, ZHANG P, LI X. Ultra fast deep lane detection with hybrid anchor driven ordinal classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(5): 2555–2568.
- [5] 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. Piscataway: IEEE Press, 2021: 3773–3782.
- [6] TABELINI L, BERRIEL R, PAIXAO T M, et al. PolyLaneNet: Lane estimation via deep polynomial regression[C]//Proceedings of the 25th International Conference on Pattern Recognition. Piscataway: IEEE Press, 2021: 6150–6156.
- [7] LIU R, YUAN Z, LIU T, et al. End-to-end lane shape prediction with transformers [C]//Proceedings of the IEEE Winter Conference on Applications of Computer Vision. Piscataway: IEEE Press, 2021: 3694–3702.
- [8] FENG Z, GUO S, TAN X, et al. Rethinking efficient lane detection via curve modeling[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 17062–17070.
- [9] NEVEN D, DE BRABANDERE B, GEORGOULIS S, et al. Towards end-to-end lane detection: An instance segmentation approach[C]//Proceedings of the IEEE Intelligent Vehicles Symposium. Piscataway: IEEE Press, 2018: 286–291.
- [10] HOU Y, MA Z, LIU C, et al. Learning lightweight lane detection CNNs by self attention distillation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019: 1013–1021.
- [11] PAN X, SHI J, LUO P, et al. Spatial as deep: Spatial CNN for traffic scene understanding [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 7276–7283.
- [12] 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.
- [13] 陈玲, 许钢, 伏娜娜, 等. 融合边缘检测的3D点云语义分割方法研究[J]. 重庆工商大学学报(自然科学版), 2022, 39(5): 1–9.
CHEN Ling, XU Gang, FU Na-na, et al. Research on 3D point cloud semantic segmentation method fused with edge detection[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(5): 1–9.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770–778.
- [15] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 4510–4520.
- [16] WANG X, LV R, ZHAO Y, et al. Multi-scale context aggregation network with attention-guided for crowd counting[C]//Proceedings of the 15th IEEE International Conference on Signal Processing. Piscataway: IEEE Press, 2020: 4510–4520.
- [17] MEHTA S, RASTEGARI M, SHAPIRO L, et al. ESPNetv2: A light-weight, power efficient, and general purpose convolutional neural network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2019: 9190–9200.
- [18] FAN M, LAI S, HUANG J, et al. Rethinking BiSeNet for real-time semantic segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 9711–9720.
- [19] LEE M, LEE J, LEE D, et al. Robust lane detection via expanded self attention[C]//Proceedings of the IEEE/CVF winter conference on applications of computer vision. Piscataway: IEEE Press, 2022: 1949–1958.
- [20] PAN H, HONG Y, SUN W, et al. Deep dual-resolution networks for real-time and accurate semantic segmentation of traffic scenes[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(3): 3448–3460.
- [21] XU G, LI J, GAO G, et al. Lightweight real-time semantic segmentation network with efficient transformer and CNN[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(12): 15897–15906.
- [22] YAO X, WANG Y, WU Y, et al. MLP-based efficient convolutional neural network for lane detection [J]. IEEE Transactions on Vehicular Technology, 2023, 72(10): 12602–12614.
- [23] XIAO D, ZHUO L, LI J, et al. Structure-prior deep neural network for lane detection[J]. Journal of Visual Communication and Image Representation, 2021, 81: 103373.
- [24] XIAO D, YANG X, LI J, et al. Attention deep neural network for lane marking detection [J]. Knowledge-Based Systems, 2020, 194: 105584.
- [25] YOO S, SEOK LEE H, MYEONG H, et al. End-to-End Lane Marker Detection via Row-wise Classification[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). IEEE, 2020: 4335–4343.

责任编辑:李翠薇