

基于轻量化卷积神经网络的车道线检测

胡杰^{1,2,3}, 熊宗权^{1,2,3*}, 徐文才^{1,2,3}, 曹恺⁴, 鲁若宇⁴

¹武汉理工大学汽车工程学院, 现代汽车零部件技术湖北省重点实验室, 湖北 武汉 430070;

²武汉理工大学汽车工程学院, 汽车零部件技术湖北省协同创新中心, 湖北 武汉 430070;

³新能源与智能网联车湖北工程技术研究中心, 湖北 武汉 430070;

⁴东风悦享科技有限公司, 湖北 武汉 430058

摘要 针对当前基于语义分割的车道线检测算法速度与精度不平衡等问题, 提出一种优化ERFNet的车道线检测算法。首先设计一个高效的核心模块, 通过引入通道分离和通道重组等操作, 大幅降低了模型参数量与计算量。其次对下采样进行调整, 增加单分支下采样, 在减少信息损失的同时提高模型并行度。最后在编码器末端引入特征融合模块, 利用空洞卷积扩大感受野, 提取不同尺度的车道线特征。在CULane数据集上对本文算法和四种基于语义分割的车道线检测算法进行对比实验, 结果表明, 在交并比阈值为0.5的情况下, 本文提出的算法综合F1评分为73.9%, 单帧图像的推理时间可达到12.2 ms, 均优于其他四种算法, 达到速度与精度的良好平衡。

关键词 机器视觉; 语义分割; 车道线检测; 空洞卷积; 特征融合

中图分类号 U491.6

文献标志码 A

DOI: 10.3788/LOP202259.1015012

Lane Detection Based on a Lightweight Convolutional Neural Network

Hu Jie^{1,2,3}, Xiong Zongquan^{1,2,3*}, Xu Wencai^{1,2,3}, Cao Kai⁴, Lu Ruoyu⁴

¹Hubei Key Laboratory of Modern Auto Parts Technology, School of Automotive Engineering,

Wuhan University of Technology, Wuhan 430070, Hubei, China;

²Auto Parts Technology Hubei Collaborative Innovation Center, School of Automotive Engineering,

Wuhan University of Technology, Wuhan 430070, Hubei, China;

³Hubei Technology Research Center of New Energy and Intelligent Connected Vehicle Engineering,

Wuhan 430070, Hubei, China;

⁴Dongfeng Yuexiang Technology Co., Ltd., Wuhan 430058, Hubei, China

Abstract This study proposes an optimized ERFNet lane detection algorithm to reduce the imbalance between the speed and accuracy of current lane detection algorithms based on semantic segmentation. First, an efficient core module is designed; introducing operations such as channel separation and channel reorganization, the number of model parameters and calculations are greatly reduced. Then, the down-sampling is adjusted to increase the single-branch down-sampling process, which improves the model parallelism while reducing information loss. Finally, a feature fusion module is introduced at the end of the encoder, and the receptive field is expanded using dilated convolution to extract differently-scaled lane features. We compare the proposed algorithm with four lane detection algorithms based on semantic segmentation on the CULane dataset. Results show that the comprehensive F1-measure of the proposed algorithm is 73.9% when the intersection-over-union is 0.5, and the inference time per image can reach 12.2 ms, which is superior to the other four models and achieves a good balance between speed and accuracy.

Key words machine vision; semantic segmentation; lane detection; dilated convolution; feature fusion

收稿日期: 2021-07-22; 修回日期: 2021-08-20; 录用日期: 2021-08-31

基金项目: 湖北省技术创新专项 (2019AEA169)、湖北省科技重大专项 (2020AAA001)

通信作者: *293014@whut.edu.cn

1 引言

伴随着人工智能的发展和汽车“新四化”政策的出台,汽车工业与计算机技术紧密结合,推动着智能汽车的迅速发展。智能汽车主要分为感知、决策、执行三大系统,而良好的环境感知能力将为后续的决策和执行系统提供稳定、可靠的信息来源。其中车道线检测是智能汽车感知系统的重要组成部分,与车道线相关的车道保持和车道偏离预警等智能驾驶辅助系统(ADAS)功能对于保障驾驶员安全具有重要作用。当前车道线检测的方法主要分为两类:基于传统方法和基于机器学习的方法。

基于传统方法的车道线检测可根据原理分为两类。1) 基于特征的检测方法^[1-4]。此类方法主要通过车道线的宽度、颜色及渐变纹理等特征进行探测提取。文献[1]提出一种基于天津法的二次阈值分割方法,在对道路图像进行二值化后,根据车道线的形态特征对图像逐行扫描得到车道线特征点,进而采用最小二乘曲线拟合算法对车道线进行分段拟合。文献[2-3]利用Canny算子进行边缘检测,然后通过Hough算法进行直线拟合,完成车道线识别。文献[4]将Pre-witt算子和Shen Jun算子结合实现噪声平滑和边缘定位,在此基础上完成车道线提取。这类方法在路面存在严重阴影、光照不均等情况时,检测效果不佳且泛化性不强。2) 基于模型的方法^[5-7]。此类方法通过借助道路的先验知识,建立适当的数学模型来拟合车道线。常见的拟合模型有:①样条曲线模型;②双曲线;③抛物线;④直线。文献[5]通过基于密度的噪声应用空间聚类(DBSCAN)算法对车道线特征点进行分类,然后利用抛物线模型对不同类的车道线特征点进行拟合。文献[6]提出一种结合Hough变换和Catmull-Rom样条曲线检测弯曲车道线的方法。文献[7]在基于双曲线双通道模型条件下,利用改进的河流流量(IRF)寻点算法与随机抽样一致性(RANSAC)算法来检测弯曲的车道线。总体来说,基于传统方法的车道线检测算法,依赖于人工设计特征,受光照强度、道路遮挡等因素的影响较大,在复杂场景下算法鲁棒性不足,已无法满足当前智能驾驶的需求。

近些年来,机器学习凭借其强大的特征提取及表征能力在包括车道线检测在内的多个研究领域发展迅速,在多种复杂场景下均能有稳定良好的结

果输出。文献[8]提出了一种集车道线检测、车道线位置预测、路面标志检测识别于一体的多任务网络VPGNet(vanishing point guided network),该网络在一般光照条件下都有良好的检测能力,在恶劣天气下仍能保持较高的车道线检测精度。文献[9]提出了空间卷积神经网络(SCNN),从空间中不同的方向传递神经元之间的消息,使其能够更好地捕获像素之间的空间关系,但是它采用直接上采样的方式,不能很好地恢复车道线边界像素。文献[10]提出了一个带分支结构的多任务网络结构,包含一个二值分割分支(lane segmentation)和一个嵌入分支(lane embedding),能够实现端到端和任意数量的车道线检测,但聚类耗时,无法满足智能驾驶技术的实时性要求。文献[11]提出一种基于扩张卷积金字塔网络的车道线检测算法,利用不同大小的卷积核,组成多尺度感受野,提高检测精度,但单帧图像的推理速度达到25 ms,过于耗时。文献[12]建立了一种结构化道路车道线检测模型,运用可变形卷积神经网络提取特征,进而对车道线进行图像语义分割并判断车道线类型。文献[13]提出一种三支车道线实例分割算法,将语义分割与实例分割相结合,对分割结果进行自适应聚类,最后用最小二乘法拟合车道线,此方法精度较高,但运行速度较慢。上述卷积神经网络为获得较高的精度,通常将网络结构设计得很复杂,从而拥有庞大的计算量,无法满足智能驾驶实时性的要求。

关于轻量化语义分割网络模型的研究也一直广受关注,例如ENet^[14]、Light-weight RefineNet^[15]、ESPNet^[16]等,但这些方法通过牺牲精度来大量压缩参数,达到提高检测速度的目的,导致无法为自动驾驶系统提供充足可靠的感知信息。

针对上述问题,本文提出一种基于改进ERFNet算法的实时车道线检测模型ERFNet-LW,能够达到速度与精度的良好平衡。首先设计了一个更加高效的核心模块shuffle-unit,减少了模型参数量和浮点数计算量。其次引入单分支下采样,减少网络并行度,提升运算效率。最后在编码器末端引入特征融合模块,将不同卷积层的特征信息有效融合,保留更多车道线像素细节以有效提高分类准确率。在公开的数据集上将本文方法与其他先进算法进行对比实验。结果表明,本文方法在运行速度最快的情况下,综合F1指标最高,达到速度与精度的良好平衡。

2 ERFNet网络结构

ERFNet^[17]是一个实时语义分割卷积网络,其网络架构的核心元素是一个新设计的残差结构——Non-bottleneck-1D,它由跳跃连接、 3×3 卷积及1D卷积核组成。跳跃连接^[18]允许卷积层利用残差方程去学习特征,并极大减缓网络结构过深造成的训练过程中梯度消失或梯度爆炸问题。非对称卷积可以用来近似替代方形卷积以达到压缩模型和加速的目的。

ERFNet采用不对称的编码器-解码器架构,如表1所示。其中1到16层属于编码器,17-23属于解码器。采用小型解码器的目的是可以对解码器的输出进行细节优化。网络的第1、2、8层是下采样模块,采用的是两分支融合。与之对应的第17、20、23是上采样模块。在这里上采样模块并未使用最大池化索引,而是使用最简单的反卷积,从而达到简化计算与缩减内存开销的目的。另外值得注意的是,ERFNet在第9到16层的Non-bottleneck-1D模块引入了空洞卷积^[19],在不增加额外参数的情况下,增大图像感受野,提升模型性能。

表1 ERFNet网络架构

Table 1 Network architecture of ERFNet

Layer	Type
1	Downsampling block
2	Downsampling block
3-7	$5 \times$ Non-bottleneck-1D
8	Downsampling block
9	Non-bottleneck-1D (dilated=2)
10	Non-bottleneck-1D (dilated=4)
11	Non-bottleneck-1D (dilated=8)
12	Non-bottleneck-1D (dilated=16)
13	Non-bottleneck-1D (dilated=2)
14	Non-bottleneck-1D (dilated=4)
15	Non-bottleneck-1D (dilated=8)
16	Non-bottleneck-1D (dilated=16)
17	Deconvolution
18-19	$2 \times$ Non-bottleneck-1D
20	Deconvolution
21-22	$2 \times$ Non-bottleneck-1D
23	Deconvolution

3 ERFNet-LW网络结构

3.1 网络框架

考虑到实际应用中的场景对象、计算资源和实

时性要求等因素,提出一种基于改进的ERFNet算法,使得模型能够达到精度与速度的良好平衡。首先对Non-bottleneck-1D优化,将提出的shuffle-unit引入通道分离操作,对卷积核重新搭配,在保证精度的同时,大幅降低了模型参数量与计算量;随后对下采样模块进行了调整,在第一次下采样时采用初始的双分支下采样,利用池化操作降低计算量、去除冗余信息,后两次下采样采用单分支下采样,不仅能更好地利用卷积核的特征提取能力,还能提高模型运算效率;最终引入特征融合模块,将空洞率不同的shuffle-unit组合不仅能够更加密集地采样,防止空洞卷积带来的棋盘效应,还能实现多尺度的车道线特征融合。改进的模型结构如图1所示。

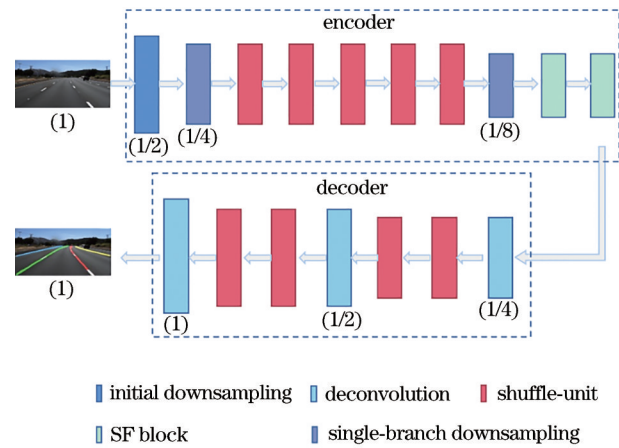


图1 ERFNet-LW网络结构

Fig. 1 ERFNet-LW network structure

本文算法模型主要由编码器和解码器组成,其中编码器主要包含下采样模块、shuffle-unit、特征融合模块,解码器包含反卷积和shuffle-unit。输入图片经过预处理后,先进入编码器部分,经过2次下采样,特征图长宽变为输入图像大小的1/4,随后图像经过连续5次shuffle-unit模块,每个模块由两分支组成,一侧是恒等映射,另一侧是 3×3 、 1×3 和 3×1 卷积核组成的串联结构。在经过第3次下采样后,特征图进入2个特征融合模块(shuffle-unit fusion block, SF block),每个特征融合模块都是由4个不同空洞率的shuffle-unit组成,以更密集的采样率获得多尺度车道线特征。由特征融合模块输出的特征图进入解码器,经过连续的反卷积和shuffle-unit后恢复到输入图像大小,得到分割结果。

3.2 Shuffle-unit

受到 ShuffleNet v2^[20]启发,对 Non-bottleneck-

1D 模块进行优化,优化后的模块命名为 shuffle-unit。如图 2 所示,引入通道分离操作(channel split),将输入特征图在通道维度分成 2 个通道数相等的分支,左侧做恒等映射,右侧分支由 3×3 、 3×1 、 1×3 卷积组成。两个分支的特征图进行特征拼接(concatenate),最后为促进信息在特征通道间流动,对拼接后的特征图结果进行通道混洗(channel shuffle)。因此 shuffle-unit 还能潜在地促进特征信息融合。

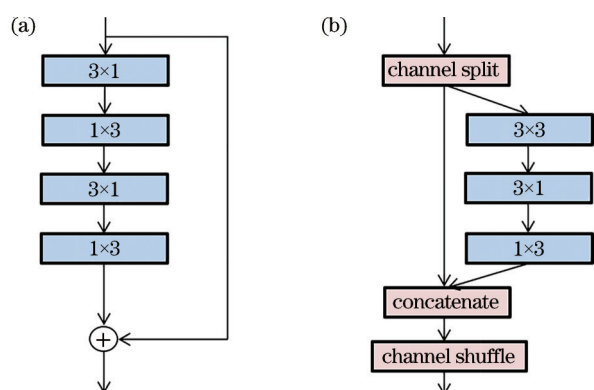


图 2 核心模块结构对比。(a) Non-bottleneck-1D;
(b) shuffle-unit

Fig. 2 Comparison of core module structure. (a) Non-bottleneck-1D; (b) shuffle-unit

对原始的 Non-bottleneck-1D 做的另外一个调整就是用一个 3×3 卷积替换了一组 3×1 、 1×3 卷积。Non-bottleneck-1D 利用低秩近似分解将 $d \times d$ 卷积分解为 $d \times 1$ 、 $1 \times d$ 卷积,降低了参数量。然而,在深度神经网络中卷积核具有分布特征,它们的固有秩高于实际值,因此,将转换直接应用到卷积核将产生显著的信息丢失^[21]。此外最近有研究发现非对称分解卷积在浅层使用的效果没有在中间层的效果好^[22],为此作者课题组用一个 3×3 卷积替换了一组 3×1 、 1×3 卷积,以期达到精度与速度的平衡。作者课题组将 Non-bottleneck-1D 替换为 shuffle-unit 后的模型叫做 ERFNet-shuffle。

对比了 ERFNet 和 ERFNet-shuffle 在 288 pixel \times 800 pixel 输入图片上参数量、浮点数运算及内存占用量等方面的变化情况。如表 2 所示,使用 shuffle-

表 2 模型指标对比

Table 2 Comparison of model indicators

Algorithm	Parameter /MB	GFLOPs	MAC /MB
ERFNet	2.67	11.47	343.30
ERFNet-shuffle	1.02	2.03	167.52

unit 模型,参数量减少 1/2 以上,浮点运算数(FLOPs)减少约 4/5,内存占用量(MAC)缩小 1/2。

3.3 下采样优化

ERFNet 下采样模块采用两分支融合进行下采样,左侧是最大池化(maxpooling)、右侧是 3×3 卷积, s 表示采样步长,最后将两个分支的结果进行特征融合。使用最大池化能够在早期起到去除冗余信息、降低计算量的作用,但当特征图变小或具有丰富的语义信息时,使用池化操作可能减弱模型对特征图的信息提取能力,并且两分支也会降低模型的并行度。本文下采样方式如图 3 所示,考虑到车道线数据集,前期图片尺寸较大,视觉信息在空间上存在着大量冗余,作者课题组在第 1 次下采样时使用初始下采样模块来降低图像信息冗余度,在后 2 次下采样时使用单分支下采样模块来发挥卷积核提取图像特征的能力以及提高模型的并行度。




图 3 下采样模块。(a) 初始下采样;(b) 单分支下采样

Fig. 3 Downsampling structure. (a) Initial downsampling; (b) single-branch downsampling

3.4 特征融合

当前大多语义分割网络都是基于全卷积网络架构(FCN)设计的,语义信息先由编码器嵌入到特征图中,再通过解码器输出得到分割结果。通常特征图经过多次下采样后需要经过双线性差值或反卷积才能恢复原图尺寸,这也造成了分辨率的损失。对此,一些研究提出采用跨层连接的方法来结合高、低层特征以弥补分辨率的损失,如 Unet^[23] 和 Refinenet^[24]。DeepLab v3^[25] 通过移除网络末端池化层,引入空洞卷积金字塔池化模块来捕获更大范围的上下文信息来检测多尺度物体。同样地,PSPNet^[26] 以并行的方式采用金字塔池化模块来集成多尺度特征信息以提高检测性能。

本文设计的特征融合模块 SF Block 如图 4 所示,特征融合模块以 shuffle-unit 为基础并引入空洞卷积提升感受野,一个特征融合模块包含 4 个 shuffle-unit,空洞率分别设为 2、4、8、16。这种不同

采样率的串联结构能够获得更密集的采样,防止空洞卷积带来的棋盘效应。受到 DeepLab v3^[25]启发,将 SF Block 的输入与每个 shuffle-unit 的输出进行并联,以此来集成不同尺度感受野特征,捕获特征图长、中、短的车道线信息。作者课题组设计的 SF Block 不仅能够以较低的计算成本获得更密集的采样,还能融合多尺度信息,覆盖更大的感受野范围。

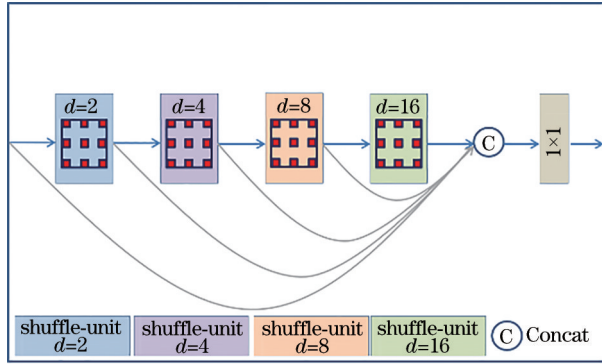


图 4 特征融合模块

Fig. 4 Feature fusion module

4 实验结果及分析

4.1 实验数据集

CULane 数据集由香港中文大学提出,由 6 辆车于不同时间在北京录制,超过 55 h 共收集了 133235 张图片。实验将数据集中的 88880 张图片作为训练集,9675 张图片作为验证集,34680 张图片作为测试集,分为正常和另外 8 个具有挑战性的类别。数据集内包括城市、农村和高速公路等场景。9 大类别及其所占比例如图 5 所示。




图 5 数据集分布

Fig. 5 Dataset distribution

CULane 数据集里,每条车道线宽度固定为 30 pixel,然后比较真实值和预测值的交并比(IoU)。

IoU 大于某一阈值的预测视为真正例(TP),否则视为假正例(FP),而漏检则视为假负例(FN),本文选取 IoU 为 0.5 作为判断阈值,基于 IoU 的评估如图 6 所示。



图 6 基于 IOU 的评估。(a)场景 1;(b)场景 2

Fig. 6 Evaluation based on IoU. (a) Scene 1; (b) scene 2

CULane 数据集将 F1 指标作为评价指标,表示为

$$F_1 = \frac{2 \times x_{\text{Precision}} \times x_{\text{Recall}}}{x_{\text{Precision}} + x_{\text{Recall}}}, \quad (1)$$

式中: $x_{\text{Precision}} = \frac{x_{\text{TP}}}{x_{\text{TP}} + x_{\text{FP}}}$, $x_{\text{Recall}} = \frac{x_{\text{TP}}}{x_{\text{TP}} + x_{\text{FN}}}$, $x_{\text{Precision}}$

为精确率,表示针对预测结果,有多少被预测为阳性的样本是真正的阳性样本; x_{Recall} 为召回率,表示针对标注样本,被标记为阳性的样本中有多少被正确预测。

4.2 实验环境

本实验所有算法均在 Ubuntu18.04 系统下,基于 Pytorch 框架运行。硬件平台为 2 块内存 10 GB 的 NVIDIA GeForce GTX1080 Ti,使用 CUDA9.2 和 CuDNN7.6 系统环境。

训练:本实验使用小批量随机梯度下降(SGD)训练网络,批大小为 8,初始学习率为 0.01,动量值为 0.9,权重衰减为 1×10^{-4} ,受文献[25, 27]的启发,采用“poly”的学习策略, $l = l \times (1 - \frac{m}{M})^p$, 式中学习指数 p 和最大迭代次数 M 分别设置为 0.9 和 100。

数据增强:在 CULane 数据集的训练中,作者课题组使用了归一化、随机旋转、随机裁剪等方法,增强模型泛化能力,防止出现过拟合现象。

4.3 实验结果及分析

首先对比了下采样优化前后 ERFNet-LW 在 CULane 数据集上的表现效果。如表 3 所示,经过下

采样优化后的模型,综合评价指标 F1 指标有一定的提升。

表 3 下采样优化前后模型在交并比阈值为 0.5 的 CULane 数据集上的 F1 指标对比

Table 3 Comparison of F1-measure on the CULane dataset with IoU of 0.5 before and after the downsampling optimization of the model

	Normal	Crowded	Night	No-line	Shadow	Arrow	Dazzlelight	Curve	Crossroad	Total
Before	91.8	72.1	69.5	46.4	67.5	86.9	65.8	67.7	2526	73.9
After	91.7	72.0	69.4	46.3	67.4	86.7	65.6	67.7	2526	73.8

随后本文将 ERFNet-LW 与 Res50-Seg^[28]、SCNN^[9]、Enet-SAD^[29]及 ERFNet^[17]等模型在 F1 指标、假正例样本个数(仅限交叉路口)等方面进行对

比。由于交叉路口子场景中的数据没有车道线标注,所以仅显示假正例样本个数,其数值越低结果越优,结果见表 4。

表 4 不同算法在 IoU 阈值为 0.5 的 CULane 数据集上的 F1 指标对比

Table 4 Comparison of F1-measure for different algorithms on CULane dataset with IoU of 0.5

Category	Res50-Seg	SCNN	Enet-SAD	ERFNet	ERFNet-LW
Normal	87.4	90.6	90.1	91.5	91.8
Crowded	64.1	69.7	68.8	71.6	72.1
Night	60.6	66.1	66.0	67.1	69.5
No-line	38.1	43.4	41.6	45.1	46.4
Shadow	60.7	66.9	65.9	71.3	67.5
Arrow	79.0	84.1	84.0	87.2	86.9
Dazzlelight	54.1	58.5	60.2	66.0	65.8
Curve	59.8	64.4	65.7	66.3	67.7
Crossroad	2505	1990	1998	2199	2526
Total	66.7	71.6	70.8	73.1	73.9

从表 4 中可以看出 ERFNet-LW 综合 F1 指标最高。ERFNet-LW 在箭头、炫光场景下 F1 指标与 ERFNet 相近,在正常、拥挤、夜晚、无车道线和曲线等场景下 F1 指标均为最优。在阴影场景下 F1 指标低于 ERFNet 但优于其他模型,相比于其他模型,ERFNet-LW 在交叉路口的性能较差,还有待进一步改进。

各模型的参数量、单帧图像推理时间对比如表 5 所示,其中运行时间为 100 次运行的平均时间,可以看出 ERFNet-LW 参数量虽多于 ENet-SAD,但运行时间最快。对 288 pixel×800 pixel 的图片,单帧图像推理时间为 12.2 ms。

图 7 展示了将 ERFNet-LW 模型放在 CULane

表 5 不同算法参数量和运行时间对比

Table 5 Comparison of parameters and runtime of different algorithms

Method	Parameter /MB	Runtime /ms
Res50-Seg	—	—
SCNN	20.72	133.5
Enet-SAD	0.98	13.4
ERFNet	2.68	14.0
ERFNet-LW	1.23	12.2

测试集不同复杂道路场景中,车道线检测结果的可视化结果。ERFNet-LW 能够适应不同场景,在强光、无车道线、拥挤等复杂场景下依然能准确检测出车道线。对于交叉路口场景,由于缺乏标注样本,模型预测效果较差,需进一步改善。

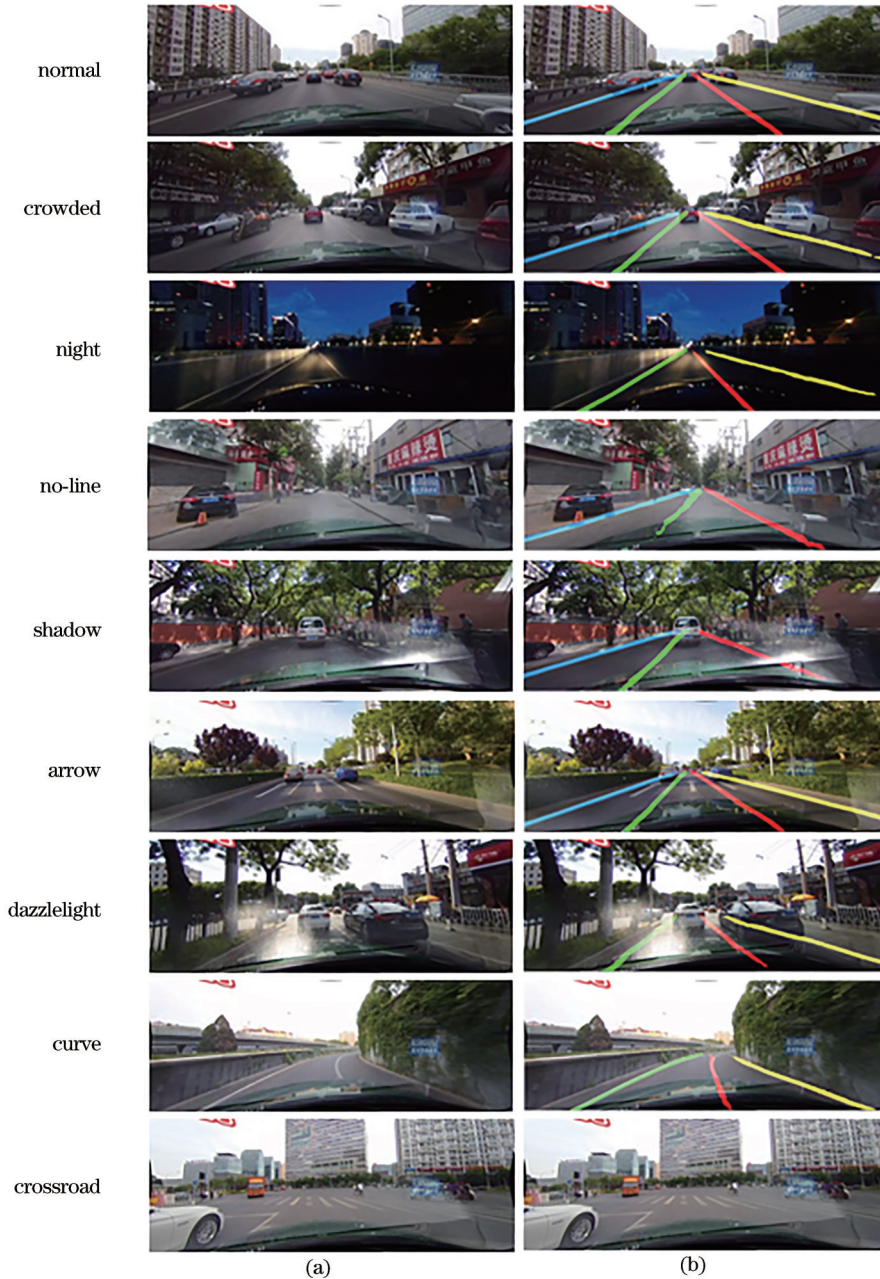


图7 CULane测试集上的可视化效果。(a)原图;(b)预测结果

Fig. 7 Visualization of CULane test sets. (a) Original image; (b) predicted results

5 结 论

为解决当前基于语义分割的车道线检测算法速度与精度不平衡的问题,提出一种ERFNet优化的车道线检测算法。首先提出一个新的核心模块,不仅能大幅降低模型参数量与计算量,还能够促进特征融合;为避免细节边界损失和提高模型并行度,引入单分支下采样,减少池化操作;最后引入空洞卷积,构建多尺度特征融合模块,有效提高模型分类性能。在公开数据集CULane上将本文算法和

4种算法进行对比,实验表明,本文所提算法不仅速度最快,综合F1指标也最高,达到速度与精度的良好平衡,即使在资源有限的情况下也依然能够满足智能驾驶中的实时性要求。

参 考 文 献

- [1] 胡胜, 黄妙华, 陈毅. 基于二次阈值分割和车道宽度匹配的车道线检测算法[J]. 汽车技术, 2019(4): 1-6.
Hu S, Huang M H, Chen Y. Lane marking detection algorithm based on double threshold segmentation and lane width[J]. Automobile Technology, 2019(4): 1-6.

- [2] 辛超, 刘扬. 基于概率霍夫变换的车道线识别算法[J]. 测绘通报, 2019(S2): 52-55.
Xin C, Liu Y. Research on lane recognition algorithm based on probability Hough transform[J]. Bulletin of Surveying and Mapping, 2019(S2): 52-55.
- [3] 王宝锋, 齐志权, 马国成, 等. 基于动态区域规划的双模型车道线识别方法[J]. 北京理工大学学报, 2014, 34(5): 485-489.
Wang B F, Qi Z Q, Ma G C, et al. Lane detection system based on region dynamically planning and dual model fitting[J]. Transactions of Beijing Institute of Technology, 2014, 34(5): 485-489.
- [4] Guo Y T, Zhang Y J, Liu S, et al. Robust and real-time lane marking detection for embedded system [M]//Zhang Y J. Image and graphics. Lecture notes in computer science. Cham: Springer, 2015, 9219: 223-235.
- [5] 洪伟, 王吉通, 刘宇, 等. 基于 DBSCAN 的复杂环境下车道线鲁棒检测及跟踪[J]. 吉林大学学报(工学版), 2020, 50(6): 2122-2130.
Hong W, Wang J T, Liu Y, et al. Robust lane detection and tracking in complex environment based on DBSCAN[J]. Journal of Jilin University (Engineering and Technology Edition), 2020, 50(6): 2122-2130.
- [6] 何鹏, 高峰, 魏厚敏. 基于 Catmull-Rom 样条曲线的弯曲车道线检测研究[J]. 汽车工程学报, 2015, 5(4): 276-281.
He P, Gao F, Wei H M. Study on curve lane detection using Catmull-Rom spline[J]. Chinese Journal of Automotive Engineering, 2015, 5(4): 276-281.
- [7] Tan H C, Yang Z, Zhu Y, et al. A novel curve lane detection based on improved river flow and RANSA [C]//17th International IEEE Conference on Intelligent Transportation Systems (ITSC), October 8-11, 2014, Qingdao, China. New York: IEEE Press, 2014: 133-138.
- [8] 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 (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 1965-1973.
- [9] Pan X G, Shi J P, Luo P, et al. Spatial As deep: spatial CNN for traffic scene understanding[EB/OL]. (2017-12-17) [2021-05-08]. <https://arxiv.org/abs/1712.06080>.
- [10] Neven D, Brabandere B D, Georgoulis S, et al. Towards end-to-end lane detection: an instance segmentation approach[C]//2018 IEEE Intelligent Vehicles Symposium (IV), June 26-30, 2018, Changshu, China. New York: IEEE Press, 2018: 286-291.
- [11] 田晟, 张剑锋, 张裕天, 等. 基于扩张卷积金字塔网络的车道线检测算法[J]. 西南交通大学学报, 2020, 55(2): 386-392, 416.
Tian S, Zhang J F, Zhang Y T, et al. Lane detection algorithm based on dilated convolution pyramid network[J]. Journal of Southwest Jiaotong University, 2020, 55(2): 386-392, 416.
- [12] 徐国晟, 张伟伟, 吴训成, 等. 基于卷积神经网络的车道线语义分割算法[J]. 电子测量与仪器学报, 2018, 32(7): 89-94.
Xu G S, Zhang W W, Wu X C, et al. Laneline semantic segmentation algorithm based on convolutional neural network[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(7): 89-94.
- [13] 周苏, 吴迪, 金杰. 基于卷积神经网络的车道线实例分割算法[J]. 激光与光电子学进展, 2021, 58(8): 0815007.
Zhou S, Wu D, Jin J. Lane instance segmentation algorithm based on convolutional neural network[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0815007.
- [14] Paszke A, Chaurasia A, Kim S, et al. ENet: a deep neural network architecture for real-time semantic segmentation[EB/OL]. (2016-06-07) [2021-05-04]. <https://arxiv.org/abs/1606.02147>.
- [15] Nekrasov V, Shen C H, Reid I. Light-weight RefineNet for real-time semantic segmentation[EB/OL]. (2018-10-08) [2021-06-04]. <https://arxiv.org/abs/1810.03272>.
- [16] Mehta S, Rastegari M, Caspi A, et al. ESPNet: efficient spatial pyramid of dilated convolutions for semantic segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11214: 561-580.
- [17] 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.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.

- [19] Wang P Q, Chen P F, Yuan Y, et al. Understanding convolution for semantic segmentation [C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV), March 12-15, 2018, Lake Tahoe, NV, USA. New York: IEEE Press, 2018: 1451-1460.
- [20] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11218: 122-138.
- [21] Jin J, Dundar A, Culurciello E. Flattened convolutional neural networks for feedforward acceleration[EB/OL]. (2014-12-17) [2021-05-04]. <https://arxiv.org/abs/1412.5474>.
- [22] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [23] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [24] Lin G S, Milan A, Shen C H, et al. RefineNet: multi-path refinement networks for high-resolution semantic segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5168-5177.
- [25] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation[EB/OL]. (2017-06-17) [2021-05-04]. <https://arxiv.org/abs/1706.05587>.
- [26] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6230-6239.
- [27] Liu W, Rabinovich A, Berg A C. ParseNet: looking wider to see better[EB/OL]. (2015-06-15) [2021-05-07]. <https://arxiv.org/abs/1506.04579>.
- [28] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [29] 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), October 27-November 2, 2019, Seoul, Korea(South). New York: IEEE Press, 2019: 1013-1021.