

DOI:10.13382/j.jemi.B2508311

# 基于特征融合与行锚点分类的车道线快速检测算法\*

张全<sup>1</sup> 周甯<sup>1</sup> 刘洋毅<sup>2</sup> 段昶<sup>3</sup> 李艳<sup>1</sup> 彭博<sup>1</sup>

(1. 西南石油大学计算机与软件学院 成都 610500; 2. 四川警察学院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:**为了解决传统图像处理方法在阴影、夜晚等复杂场景下车道线检测实时性和准确性难以兼顾的问题,提出了一种基于特征融合与行锚点分类的车道线快速检测算法,以适应实时交通场景的需求。在图像预处理阶段,将图像划分为网格状的行锚点,将车道线检测转化为行锚点分类问题,显著降低计算量。车道线检测网络采用 ResNet-18 作为骨干网络,并引入聚合模块增强上下文特征提取,提升车道线结构信息捕捉能力;结合特征金字塔网络(FPN)进行多尺度特征融合,实现车道线局部特征与全局特征的互补;此外,引入含 ASPP 模块的辅助分割分支,进一步优化车道线检测精度。在公开数据集 TuSimple 和 CULane 上进行实验, TuSimple 数据集上的精确度达到 96.16%, 运行耗时仅为 3.2 ms; CULane 数据集上取得了 70.3% 的 F1 分数, 帧率达到 310 fps。实验结果表明,所提方法在保证检测精度的同时,显著提高了检测速度。

**关键词:** 车道线检测; 多尺度特征; 卷积神经网络; ASPP; 特征金字塔网络

**中图分类号:** TP391.4; TN911.73

**文献标识码:** A

**国家标准学科分类代码:** 510.4

## Fast lane detection algorithm based on feature fusion and row anchor classification

Zhang Quan<sup>1</sup> Zhou Ning<sup>1</sup> Liu Yangyi<sup>2</sup> Duan Chang<sup>3</sup> Li Yan<sup>1</sup> Peng Bo<sup>1</sup>

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

2. Intelligent Policing Key Laboratory of Sichuan Province, Sichuan Police College, Luzhou 646000, China;

3. School of Electrical Engineering and Information, Southwest Petroleum University, Chengdu 610500, China)

**Abstract:** In order to solve the problem of difficulty in balancing real-time and accuracy of lane detection in complex scenes such as shadows and nights using traditional image processing methods, a fast lane detection algorithm based on feature fusion and anchor point classification is proposed to meet the needs of real-time traffic scenes. In the image preprocessing stage, the image is divided into grid like row anchors, and lane detection is transformed into a row anchor classification problem, significantly reducing computational complexity. The lane detection network adopts ResNet-18 as the backbone network and introduces an aggregation module to enhance context feature extraction and improve the ability to capture lane structure information. Combining feature pyramid network (FPN) to achieve multi-scale feature fusion and complement local and global features of lane markings. In addition, an auxiliary segmentation branch with ASPP module is introduced to further optimize the accuracy of lane detection. Experiments were conducted on the public datasets TuSimple and CULane, and the accuracy on the TuSimple dataset reached 96.16%, with a running time of only 3.2 ms; Obtained 70.3% F1 score and FPS of 310 fps on the CULane dataset. The experimental results show that the proposed method significantly improves detection speed while ensuring detection accuracy.

**Keywords:** lane detection; multi-scale features; convolutional neural network; ASPP; feature pyramid network

## 0 引言

近年来,智能驾驶技术已成为交通安全研究的前沿热点。其中,视觉目标识别技术在汽车安全辅助驾驶系统(advanced driver assistance system, ADAS)中扮演着至关重要的角色。车道线作为车辆行驶过程中至关重要的视觉参考信息,其检测精度与检测速度直接决定了车辆辅助驾驶系统的性能表现。尤其在城市快速路、高速公路等高动态交通环境下,系统若不能在极短时间内完成高精度的车道线检测,将极易造成路径偏移、误判甚至引发安全事故。因此,兼顾车道线检测的实时性与准确性具有重要意义。

目前车道线检测方法主要分为基于图像处理的传统方法和基于深度学习的方法两种。基于图像处理的传统方法主要是通过获取车道线的颜色、纹理等特征<sup>[1]</sup>,并基于参数对车道曲线进行建模拟合。Xu 等<sup>[2]</sup>利用 HSL 颜色空间实现车道线检测,吕侃徽等<sup>[3]</sup>结合 Hough 变换与密度空间聚类,实现车道线的检测。PolyLaneNet<sup>[4]</sup>采用多项式回归问题,实现了高效率的车道线检测。这类方法一般是根据车道线的颜色、纹理等视觉线索进行检测,这些方法在简单场景中表现良好,但在复杂的实际交通环境中,容易受到遮挡、阴影等因素的影响,传统方法的检测效果显著降低。

目前基于深度学习的车道线检测方法包括两类,一类是基于分类的方法,另一类是基于分割的方法。基于分类的方法是将图像划分为可学习的块或单元,然后将车道线检测任务转换为对每个单元进行逐行分类的任务。Qin 等<sup>[5]</sup>在图像上使用大区域的行表示车道线并在一定程度上解决了检测速度的问题,但在精度方面存在不足。朱娟等<sup>[6]</sup>通过引入注意力机制和扩大感受野的方式来处理复杂的道路场景,但模型检测精度不佳。

基于分割的方法是将车道线检测视为语义分割任务,采用逐像素预测的方式将车道线区域从背景中分离。Zheng 等<sup>[7]</sup>提出了实时特征聚合模块 RESA (recurrent feature-shift aggregator),该模块利用周期性切片使网络能够聚集全局特征,提高性能。Pan 等<sup>[8]</sup>利用带有消息传递机制,提出空间卷积神经网络 (spatial CNN, SCNN) 方法来改善车道线检测中的空间关系,取得了不错的检测精度。潘玉恒等<sup>[9]</sup>提出的 ResNeXt 方法通过引入生成式对抗网络,增强了模型分类能力。郑剑等<sup>[10]</sup>提出 MRFP 模块和 CTI 模块用于解决特征提取尺度单一等问题,但面对复杂场景时其精度有所欠缺。Neven 等<sup>[11]</sup>将车道线检测任务看作为逐像素分割任务,尽管在保证了一定精度,但在检测速度上存在不足。蒯晓等<sup>[12]</sup>利用多分支结构和跳跃连接结构实现跨层特征的融合,但在检测速度

方面有所欠缺。Liu 等<sup>[13]</sup>采用基于条件卷积的车道检测方法,并提出了递归实例模块,以应对复杂结构的车道线处理。Hou 等<sup>[14]</sup>提出了一种自注意力蒸馏方法 SAD,来进一步利用上下文的语义信息,但由于其像素级的处理,计算量较大,不能较好地满足实时性要求。

为满足车道线检测实时性和准确性的双重要求,本文提出一种基于特征融合与行锚点分类的车道线快速检测算法。首先,将图像划分为网格状的行锚点,用行锚点表示车道线,将车道线检测任务转化为行锚点分类任务。与逐像素分割方法相比,这种方法有效地减少了计算量。同时,行锚点的划分是在整个图像上进行的,拥有更大的感受野,保留了更多的全局信息。车道线检测网络中,为了增强特征提取,将聚合模块融入骨干网络 ResNet-18 中,提升车道线结构信息捕捉能力;结合特征金字塔网络(feature pyramid network, FPN)<sup>[15]</sup>实现多尺度特征融合,有效实现车道线局部与全局特征的互补;此外,引入含空洞空间金字塔池化(atrous spatial pyramid pooling, ASPP)<sup>[16]</sup>模块的辅助分割分支,进一步优化车道线检测精度。

## 1 基于行锚点的车道线表示

本文采用行锚点来表示车道线,如图 1 所示,首先进行图像预处理。将图像尺寸调整为  $288 \times 800$ , 然后对图像进行网格化处理,先沿高度方向将图像划分为特定数量的行,再将每一行细分为多个单元格,每个单元格即为一个行锚点。

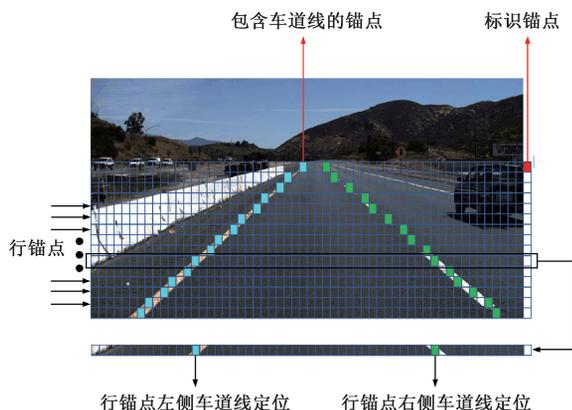


图 1 行锚点分类示意图

Fig. 1 Schematic diagram of anchor point classification

在网格化过程中,假设图像中包含车道线的条数为  $C$ , 图像尺寸为  $H \times W$ , 划分的行数量为  $h$ , 每一行中划分的行锚点数量为  $w$ 。在网格化过程中,满足条件  $h \ll H$ ,  $w \ll W$ 。同时,为了高效处理车道线信息,本文在每一行中预设了一个标识锚点,用于判断该行中是否包含车道

线信息。本文车道线表示方法的计算量为  $C \times h \times (w + 1)$ , 逐像素分割方法的计算量为  $C \times H \times W$ , 与逐像素分割的方法相比, 本文方法的计算量显著降低。同时, 本文中锚点划分是在整个图像上进行的, 拥有更大的感受野, 包含更多全局信息。

图像经过网格化处理后, 图像中的车道线信息也会包含在行锚点中, 车道线检测就可以看作为对预定义的行锚点进行分类, 并选择出包含车道线信息的行锚点。行锚点分类是逐行进行的, 具体步骤是识别每一行中包含车道线信息的行锚点, 将同属于一条车道线的锚点合并为一个整体。如果同一行的行锚点中包含多条车道线信息, 则对行锚点进行进一步分类, 将同属一条车道线的锚点归为一类。图 1 中, 左侧车道线的行锚点归为一类, 右侧车道线的行锚点归为一类, 对于不包含车道线信息的行, 该行的标识锚点会被设置为特定的值, 表示该行的

锚点中不含车道线信息。通过这种车道线的表示方式, 能够显著减少计算量, 提高车道线检测速度。

## 2 车道线检测网络

车道线检测网络是以轻量化的 ResNet-18 作为骨干网络, 并在此基础上融入其他功能模块, 构建出的复合型网络结构。同时, 为了加强骨干网络的特征提取能力, 在 ResNet-18 的基础上引入聚合模块, 以增强上下文特征提取, 提升车道线结构信息捕捉能力。车道线检测网络结构如图 2 所示。原始图像输入网络之前, 首先对其进行预处理操作, 将图像划分为由多个行锚点组成的网格结构。通过这种方式, 将车道线检测任务从逐像素点的分类问题转化为行锚点的分类问题, 显著降低了计算复杂度。

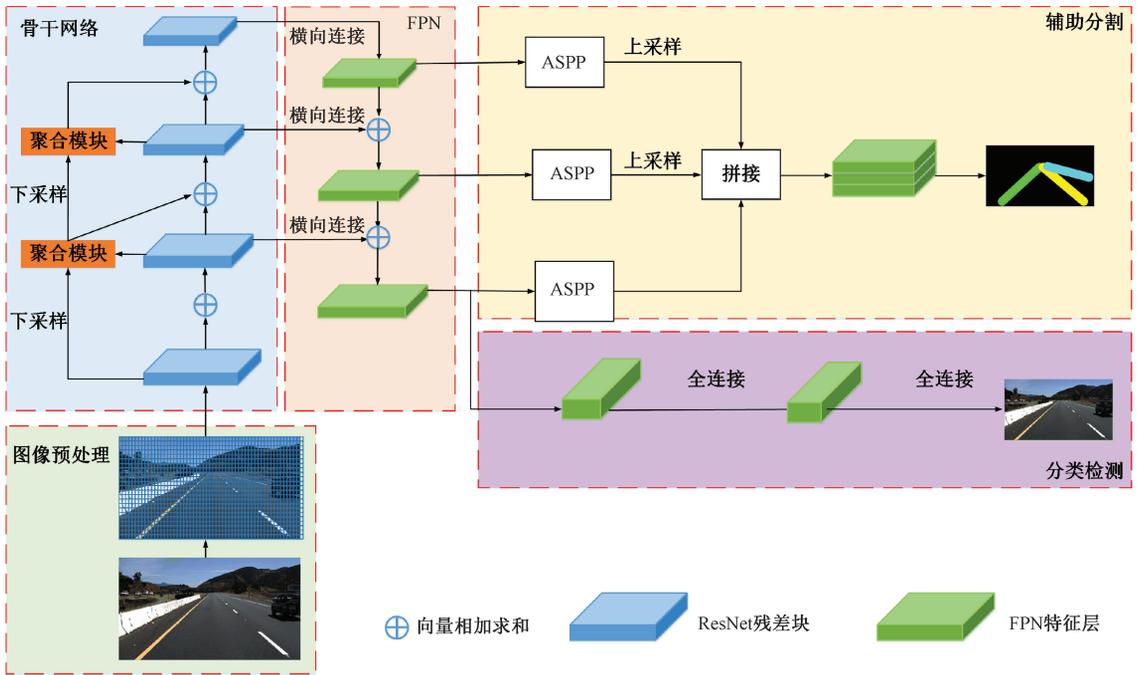


图 2 车道线检测网络结构

Fig. 2 Structure diagram of lane line detection network

图像预处理完成后, 由骨干网络提取出图像中不同层级的车道线特征, ResNet-18 四个不同层级残差块输出的特征形状分别为  $64 \times 72 \times 200$ 、 $128 \times 36 \times 100$ 、 $256 \times 18 \times 50$ 、 $512 \times 9 \times 25$ 。随后将多个不同层级的特征信息输入 FPN, 进行多尺度特征融合, 生成 3 个不同层级的多尺度特征。在网络的后处理阶段, FPN 输出的多尺度特征被用于两个分支任务, 分别为辅助分割分支和分类检测分支。在辅助分割中, FPN 生成的 3 个不同层级的多尺度特征分别经过 ASPP 模块处理, 处理后的多尺度特征被整合拼接, 生成分割结果。该分支的主要目的是通过

引入辅助分割损失, 在训练阶段优化整体网络性能, 从而提升对车道线的感知能力, 为任务的分类检测提供有效指导。辅助分割仅在训练阶段启用, 在推理阶段禁用, 以避免额外计算开销对检测速度的影响。通过这种设计, 辅助分割在训练时对主任务起到间接增强作用, 不影响推理时的效率与结果。

在分类检测分支, 利用两个全连接层处理 FPN 最深层的特征输出并调整维度, 生成最终的检测结果。整体的网络结构通过高效的特征提取与多尺度信息融合, 实现对车道线的检测。

## 2.1 聚合模块

在车道线检测任务中,由于车道线是细长而连续的结构,同时依赖局部纹理和全局形状,全局特征可以捕获抽象语义信息(如车道线整体走向),局部特征保留局部纹理和边缘信息。传统的 ResNet 作为骨干网络虽然能够逐层提取特征,但 ResNet 的各级残差块之间是直接堆叠拼接的,各级残差块之间缺少特征交互,导致传统的 ResNet 在捕捉全局上下文信息和多尺度语义细节方面存在一定局限。为此,本文提出聚合模块,并将其融入到 ResNet 中,以加强不同层级特征之间的融合与传递。在聚合模块中将前一级的局部特征与后一级的全局特征进行拼接再卷积,可以让网络同时利用全局上下文信息和局部细节,提高车道检测的精度。

同时,为了保证检测速度的前提下控制网络参数量,本文所提出的聚合模块设计注重简洁性,以 ResNet-18 第 1 个层级下采样后的输出和第 2 个层级输出为例,聚合模块结构如图 3 所示。前一个层级特征首先进行下采样调整尺寸大小,便于后续进行通道维度的拼接。聚合模块首先通过 concat 操作将当前层级与上一层级下采样后的特征沿通道维度进行拼接,形成一个更大的特征图。拼接后的特征图包含来自不同层次的全局信息和细节信息,使得特征表达更加丰富。接着,经过一个  $1 \times 1$  的卷积操作进行特征融合,以平衡不同层次特征的贡献,并生成新的特征图。该新特征图不仅显式地保留了车道线的全局结构信息,还为后续的车道线检测任务提供了更加细致且多样化的特征表示。

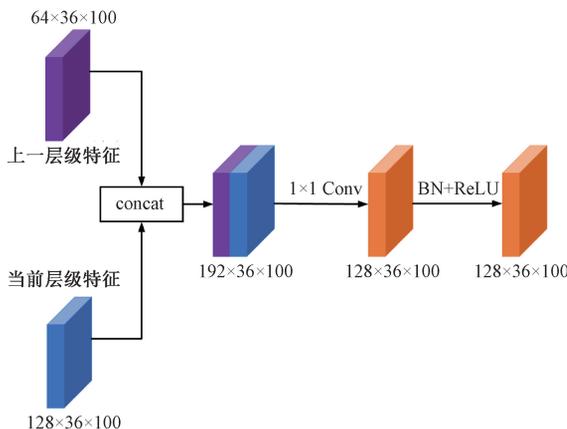


图 3 聚合模块

Fig. 3 Aggregation module

## 2.2 特征金字塔网络

全局特征的提取对于捕捉车道线整体结构信息、理解目标之间的上下文关系具有重要意义。FPN 通过自顶向下的特征融合策略,有效整合不同层级的语义与细节信息,显著增强了模型对全局特征的建模能力,尤其在多

尺度目标检测任务中表现突出。

为提升车道线检测网络对全局特征的提取能力以及多尺度目标的检测效果,本文在网络结构中引入了 FPN。由图 2 可见,FPN 接收来自骨干网络后 3 个层级的特征图作为输入,首先通过横向连接对各层特征进行通道压缩,以减少计算开销并保证特征一致性。随后,FPN 采用自顶向下的特征融合策略,从高层特征开始逐层上采样,并与相应的低层特征逐元素相加,实现多尺度信息的有效整合。在本文的网络结构中,FPN 输出的特征既被用于辅助分割分支,也被直接传递到分类检测分支,提高了分类与分割的性能。

## 2.3 辅助分割

由图 2 可知,车道线检测网络中设置了辅助分割分支,该分支接收来自 FPN 的 3 个不同尺度的特征图。为了增强特征表达能力,分别对这 3 组特征引入 ASPP 模块进行多尺度上下文信息提取。随后,将处理后的特征进行拼接整合,生成最终的辅助分割输出。最终辅助分割输出会与分割标签进行比较,并得到辅助分割损失,在训练阶段优化整体网络性能。

ASPP 是一种结合了空洞卷积的多尺度特征提取模块,通过在多个分支中使用不同膨胀率的空洞卷积实现了感受野的扩大,并将输出进行融合得到最终输出,从而实现多尺度上下文信息的提取。

ASPP 模块结构如图 4 所示,该模块对输入的特征图应用多个空洞卷积及全局平均池化操作,每个空洞卷积具有不同的膨胀率。空洞卷积通过扩展卷积核的感受野,能够有效地捕捉到车道线的轮廓、形态等信息。随后,将不同膨胀率的卷积结果和全局平均池化的结果通过拼接进行特征融合,形成一个多尺度的特征表示。多尺度特征融合使得网络可以在不同层次上同时考虑全局与局部信息,增强了模型对车道线形态变化的敏感性。融合后的特征图通过一个  $1 \times 1$  卷积进行降维,得到最终输出。ASPP 模块的多尺度设计能够在不同尺度下精细地捕捉车道线局部的细节变化。通过这种方式,辅助分割网络的精度得到了提升,从而进一步提高了主网络对车道线的检测能力。

## 2.4 损失函数

损失函数由分割损失和分类损失两部分组成。分割损失用于衡量辅助分割分支生成的分割结果与分割标签之间的差异,其计算公式如下:

$$L_{seg} = L_{CE}(S_{pred}, S_{gt}) \quad (1)$$

式中: $L_{CE}$  表示标准交叉熵损失函数; $S_{pred}$  为辅助分割分支的预测结果; $S_{gt}$  为对应的分割标签。

分类损失用于衡量分类检测分支生成的检测结果与分类标签之间的差异,其计算公式如下:

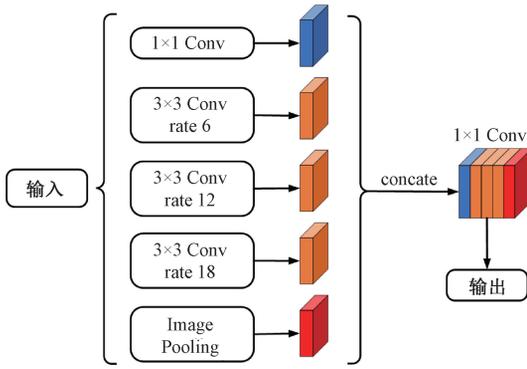


图 4 ASPP 模块

Fig. 4 ASPP module

$$L_{cls} = L_{BCE}(L_{pred}, L_{gt}) \quad (2)$$

式中:  $L_{BCE}$  表示二进制交叉熵损失函数;  $L_{pred}$  为分类检测

分支的预测结果;  $L_{gt}$  为对应的分类标签。总损失函数计算公式为:

$$L_{total} = L_{seg} + L_{cls} \quad (3)$$

### 3 实验结果与分析

#### 3.1 实验设置

##### 1) 数据集

实验使用两个公开的车道线检测数据集: CULane 和 TuSimple。CULane 数据集由 133 235 张图像组成, 其中包含了 9 种不同的场景, 该数据集采集于乡镇道路和城市道路。TuSimple 是在光照稳定条件下采集的美国高速公路场景数据集, 其中包含了 6 408 张图像。关于两个数据集的详情如表 1 所示。

表 1 数据集详情

Table 1 Dataset details

数据集	图像总数	训练集	验证集	测试集	分辨率	车道数	环境	场景
CULane	133 235	88 880	9 675	34 680	1 640×590	≤4	9	城区和高速公路
TuSimple	6 408	3 268	358	2 782	1 280×720	≤5	1	高速公路

##### 2) 实验环境及参数设置

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。CULane 数据集使用 SGD 优化器, 基础学习率设置为 0.1, 权重衰减率为 0.000 1, batch-size 设置为 32, 训练 50 轮。

TuSimple 数据集使用基础学习率为 0.000 5 的 Adam 优化器, 权重衰减率为 0.000 1, batch-size 设置为 64, 训练 100 轮。由于数据集中图像分辨率不同, 数据集中行锚点参数设置有所差异。对于 CULane 数据集, 图像高度方向被划分为 18 行, 每一行划分为 200 个行锚点; 对于 TuSimple 数据集, 图像高度方向被划分为 56 行, 每一行细分为 100 个行锚点。

##### 3) 评价指标

对于 CULane 和 TuSimple 两个数据集, 官方的评价指标是不同的。CULane 数据集的评价指标是 F1 分数。F1 分数是一种用于衡量模型性能的指标, 综合了精确率 (precision) 和召回率 (recall)。F1 分数具体计算公式如式 (4)。TuSimple 数据集的官方评价指标是准确率 (Acc), Acc 的计算公式如式 (5) 所示。

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

$$Acc = \frac{\sum_{clip} C_{clip}}{\sum_{clip} S_{clip}} \quad (5)$$

式中:  $C_{clip}$  是正确预测的车道点数量;  $S_{clip}$  是数据集标签

中的总数量。

#### 3.2 消融实验

为了验证车道线检测网络中各个模块的有效性, 本文在 CULane 数据集上进行消融实验。在 ResNet-18 的基础上, 逐步引入聚合模块、FPN 以及辅助分割, 以验证各个模块对整体性能提升的有效性。消融实验结果如表 2 所示, 仅使用基础模型时, 模型的 F1 分数为 68.2%。加入聚合模块后, 模型 F1 分数提升至 69.1%, 这表明聚合模块在增强特征提取能力方面起到了积极作用。进一步引入 FPN 后, 模型的 F1 分数提高至 69.8%, 这说明 FPN 提升多尺度特征融合的能力对于车道线检测任务有良好的效果。辅助分割的引入将模型 F1 分数提高至 70.3%, 这表明辅助分割分支的引入能够在训练阶段优化整体网络性能。

表 2 消融实验

Table 2 Dataset details

ResNet-18	聚合模块	FPN	辅助分割	F1/%
√				68.2
√	√			69.1
√	√	√		69.8
√	√	√	√	70.3

#### 3.3 对比实验

为评估模型性能, 本文在 CULane 和 TuSimple 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对比实验。

由于 TuSimple 数据集在光照稳定条件下采集且数据集中的交通场景相对简单,目前的车道线检测模型在该数据集上普遍能够实现较高精度的检测,因此不同方法之间的准确率差异不大。如表 3 所示,本文方法在 TuSimple 数据集上的检测耗时仅为 3.2 ms,是表 3 中最优的,且准确率为 96.16%,在所有对比方法中处于较高水平,DAMLaP-Net 方法在准确率上表现最佳,达到了 96.46%。本文方法的准确率与 DAMLaP-Net 方法仅相差 0.3%。然而,AMLAP-Net 方法的运行耗时为 12.7 ms,约为本文方法的 4 倍,本文方法具有明显的速度优势。本文方法在 TuSimple 数据集上展现出优异的综合性能,不仅准确率超过了 96%,而且在运行时间上具有显著的优势。

表 3 TuSimple 数据集性能对比结果

Table 3 Performance comparison results of TuSimple

方法	Acc/%	运行时间/ms
Res34-Seg <sup>[16]</sup>	92.84	50.5
PolyLaneNet <sup>[4]</sup>	93.36	6.1
Res34-LaneATT <sup>[17]</sup>	95.63	5.9
Res18-UFLD <sup>[5]</sup>	95.81	3.2
DAMLaP-Net <sup>[18]</sup>	96.46	12.7
LaneNet <sup>[11]</sup>	96.38	19
Res18-UFSALD <sup>[19]</sup>	96.03	7.3
SGRNeXt <sup>[9]</sup>	95.7	18.6
MVTLane-S <sup>[20]</sup>	95.65	6.4
LkLaneNet <sup>[21]</sup>	95.94	7.9
EL-GAN <sup>[22]</sup>	96.39	>100
本文	96.16	3.2

在 CULane 数据集上的实验结果如表 4 所示。CULane 数据集中共包含了 9 个不同的道路场景正常

(Normal)、拥堵(Crowed)、夜晚(Night)、遮挡(No-line)、阴影(Shadow)、箭头(Arrow)、强光(Dazzlelight)、弯道(Curve)、路口(Crossroad),其中 Crossroad 场景并未标注真实的车道线,因而仅采用假正例(FP)作为评价指标,该指标越低越好。其余 8 个场景的评价指标均为 F1 分数,该指标高越好。本文方法在 CULane 数据集上取得了 70.3%的 F1 分数位居前列。相较于使用分割的 Res50-seg 方法,本文方法的 F1 分数高出 3.6%,显著优于 Res50-seg 方法。F1 分数最高的是 SCNN 方法,其分数为 71.6%,比本文方法高出 1.3%。此外,Res34-SAD 和 SAD 方法的 F1 分数略高于本文方法,而其他方法的 F1 分数均低于本文方法。处理速度方面,本文方法的帧率达到了 311 fps,仅略低于 Res18-UFLD 方法的 322 帧,但本文方法 F1 分数比 Res18-UFLD 方法提升了 1.9%。SCNN 方法虽然 F1 分数达到了 71.6%,是表中最高,但其帧率仅为 7.5 fps,处理速度远低于本文方法,相差超过 40 倍。Res34-SAD 的帧率为 19.8 fps,SAD 的帧率为 74.6 fps,均远低于本文方法。综上所述,本文方法综合性能最佳,兼顾了实时性与准确性。

### 3.4 可视化结果分析

本文方法可视化结果如图 5 所示,CULane 数据集涵盖的 9 种复杂场景下的车道线检测效果。图 5 中,在无干扰的正常场景下,车道线检测准确;而在拥挤、夜晚、阴影、强光和路口等复杂环境下,检测结果同样准确。此外,对于左右两侧存在车辆遮挡的情况,方法依然能够稳定检测到车道线。在带有箭头标识的场景中,本文方法成功检测出车道线,未出现误检。在弯道场景中,整体检测效果较好。但由于行锚点采用网格状表示,在弯道幅度较大的区域,行锚点对车道线的整体刻画精度有所降低,导致检测准确性略有下降。本文方法在上述复杂场景中展现出优秀的性能,能够实现车道线的准确检测。

表 4 CULane 数据集性能对比结果

Table 4 Performance comparison results of CULane

Category	Res50-seg <sup>[16]</sup>	Res34-SAD <sup>[13]</sup>	SAD <sup>[13]</sup>	SCNN <sup>[8]</sup>	FD-50 <sup>[23]</sup>	Res18-UFLD <sup>[5]</sup>	Res18-UFSALD <sup>[19]</sup>	本文
Normal	87.4	89.9	90.1	90.6	85.9	87.7	89.1	89.5
Crowed	64.1	68.5	68.8	69.7	63.6	66.0	69.6	68.8
Night	60.6	64.6	66.6	66.1	57.8	62.1	65.3	64.1
No-line	38.1	42.2	41.6	43.4	40.6	40.2	38.4	40.7
Shadow	60.7	67.7	65.9	66.9	59.9	62.8	68.9	60.4
Arrow	79.0	83.8	84	84.1	79.4	81.0	84.4	83.9
Dazzlelight	54.1	59.9	60.2	58.5	57.0	58.4	57.3	58.3
Curve	59.8	66.0	65.7	64.4	65.2	57.9	59.1	58.4
Crossroad	2 505	1 960	1 998	1 999	7 013	1 743	2 218	1 809
Total	66.7	70.7	70.8	71.6	—	68.4	70.2	70.3
帧率/fps	—	19.8	74.6	7.5	—	322	143	311



图 5 可视化结果

Fig. 5 Visualization results

## 4 结 论

本文提出了一种基于特征融合与行锚点分类的车道线快速检测算法,旨在满足车道线检测实时性和准确性的双重要求。该方法通过将图像细分为网格形状的行锚点,将车道线检测任务转化为对行锚点分类,从而显著降低了计算复杂度并提升了检测速度。为了进一步增强网络的性能,在模型中引入了聚合模块,以提升特征提取的能力。通过集成 FPN,本文方法在处理多尺度信息方面展现出了良好的能力。此外,在辅助分割网络中融入了 ASPP 模块,有效扩大了网络的感受野,提升了辅助分割的精度,进而促进了主网络检测精度的整体提升。本文在 CULane 和 TuSimple 两个公开数据集上进行实验,结果表明,本文方法在保证检测精度的同时,显著提升了检测速度。然而,在面对转弯幅度较大的弯道场景时,检测结果仍有提升空间。未来工作将致力于优化模型在弯道场景的检测精度,进一步增强其在多样化和复杂交通环境下的鲁棒性。

### 参考文献

- [ 1 ] 吴骅跃, 赵祥模. 基于 IPM 和边缘图像过滤的多干扰车道线检测 [J]. 中国公路学报, 2020, 33(5): 153-164.  
WU H Y, ZHAO X M. Multi-interference lane recognition based on IPM and edge image filtering [J]. China Journal of Highway and Transport, 2020, 33(5): 153-164.
- [ 2 ] XU D. Color-enhanced lane line detection algorithm

based on HSL color space [C]. Third International Conference on Computer Graphics, Image, and Virtualization, 2023, 12934:483-490.

- [ 3 ] 吕佩徽, 张大兴. 基于改进 Hough 变换耦合密度空间聚类的车道线检测算法 [J]. 电子测量与仪器学报, 2020, 34(12): 172-180.  
LYU K H, ZHANG D X. Lane detection algorithm based on improved Hough transform coupled density space clustering [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 172-180.
- [ 4 ] TABELINI L, BERRIEL R, PAIXÃO T M, et al. PolyLaneNet: Lane estimation via deep polynomial regression [C]. 2020 25th International Conference on Pattern Recognition, 2020.
- [ 5 ] 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.
- [ 6 ] 朱娟, 朱国吕, 岳晓峰. 融合 CAM 和 ASPP 的车道线检测算法研究 [J]. 重庆理工大学学报(自然科学), 2024, 38(5): 86-94.  
ZHU J, ZHU G L, YUE X F. Research on lane line detection algorithm fusion CAM and ASPP [J]. Journal of Chongqing University of Technology (Natural Science), 2023, 37(7): 44-50.
- [ 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 ] 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.
- [ 9 ] 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.
- [ 10 ] 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.
- [ 11 ] 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.
- [ 12 ] 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.
- [ 13 ] 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.
- [ 14 ] 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, 2019:1013-1021.
- [ 15 ] LIN TY, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [ C ]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017:936-944.
- [ 16 ] 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.
- [ 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, 2021.
- [ 18 ] 贾远鹏,陈学文,哈瑞峰.双注意力机制下自动驾驶汽车车道线深度感知研究[J].重庆理工大学学报(自然科学),2023,37(7):44-50.
- JIA Y P, CHENG X W, HA R F. Research on lane depth perception of autonomous vehicles with dual attention mechanism [ J ]. Journal of Chongqing University of Technology ( Natural Science ), 2023, 37(7):44-50.
- [ 19 ] 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.
- [ 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 ] LI S, WU X, WU Z. Efficient multi-lane detection based on large-kernel convolution and location [ J ]. IEEE Access, 2023, 11:58125-58135.
- [ 22 ] GHAFORIAN M, NUGTEREN C, BAKA N, et al. EL-GAN: Embedding loss driven generative adversarial networks for lane detection [ C ]. European Conference on Computer Vision, 2018:256-272.
- [ 23 ] PHILION J. FastDraw: Addressing the long tail of lane detection by adapting a sequential prediction network [ C ]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019:11574-11583.

## 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.