

基于RepVGG网络的实时车道线检测方法

蔡汶良, 黄俊

引用本文

蔡汶良, 黄俊. 基于RepVGG网络的实时车道线检测方法[J]. 计算机科学, 2024, 51(7): 236-243.

CAI Wenliang, HUANG Jun. Lane Detection Method Based on RepVGG[J]. Computer Science, 2024, 51(7): 236-243.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于彩色图像高频信息引导的深度图超分辨率重建算法研究](#)

Study on Algorithm of Depth Image Super-resolution Guided by High-frequency Information of Color Images

计算机科学, 2024, 51(7): 197-205. <https://doi.org/10.11896/jsjcx.230400102>

[一种基于谱图SIFT的同源频谱监测数据判定方法](#)

Method for Homologous Spectrum Monitoring Data Identification Based on Spectrum SIFT

计算机科学, 2024, 51(6A): 230300177-7. <https://doi.org/10.11896/jsjcx.230300177>

[RM-RT²NI:融合评论时效与可信近邻影响力的推荐模型](#)

RM-RT²NI: A Recommendation Model with Review Timeliness and Trusted Neighbor Influence

计算机科学, 2024, 51(6A): 230800160-7. <https://doi.org/10.11896/jsjcx.230800160>

[融入类别标签和主题信息的用户兴趣识别方法](#)

User Interest Recognition Method Incorporating Category Labels and Topic Information

计算机科学, 2024, 51(6A): 230500169-8. <https://doi.org/10.11896/jsjcx.230500169>

[卷烟厂卷包车间工人违规作业行为检测方法](#)

Detection Method for Workers' Illegal Operation Behavior in Packaging Workshop of Cigarette Factory

计算机科学, 2024, 51(6A): 230700123-8. <https://doi.org/10.11896/jsjcx.230700123>

基于 RepVGG 网络的实时车道线检测方法

蔡汶良 黄俊

重庆邮电大学通信与信息工程学院 重庆 400065

(cwl990110@163.com)

摘要 针对现有车道线检测方法存在的检测速度慢、检测精度低的问题,将车道线检测视为分类问题,提出了基于 RepVGG 网络的实时车道线检测方法。在 RepVGG 网络中融合不同层级特征图,减少空间定位信息的损失,提高车道线的定位精度。采用曲线建模的后处理方法,从整体和局部两个角度修正车道线预测结果。挖掘车道线定位中的分布信息,提出了基于分布指导的车道线存在预测分支,直接从车道线定位分布中学习车道线的存在特征,在略微提升推理速度的同时进一步提升检测精度。在 TuSimple 和 CULane 数据集上的实验表明,该模型在检测速度和精度上取得了良好的平衡。在 CULane 数据集上,所提方法的推理速度为目前同类方法中检测速度最快的 UFLDv2 算法的 1.13 倍,同时 F1 分数从 74.7% 提高到 77.1%,达到了实时检测任务的需求。

关键词: 计算机视觉; RepVGG; 车道线检测; 曲线拟合; 特征融合; 后处理

中图分类号 TP391

Lane Detection Method Based on RepVGG

CAI Wenliang and HUANG Jun

School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract Aiming at the problems of slow detection speed and low detection accuracy in existing lane detection methods, lane detection is regarded as a classification problem, and a lane detection method based on RepVGG is proposed. Based on the RepVGG model, different levels of feature maps are fused in the backbone network to reduce the loss of spatial positioning information and improve the accuracy of lane positioning. Modeling lane as a whole and correcting lane line prediction effects from both overall and local perspectives through post-processing. Introducing a branch of lane presence prediction based on distribution guidance to learn the lane presence features directly from the localization distribution, working in conjunction with post-processing to further improve the detection accuracy while enhancing the inference speed. Experiments on the TuSimple dataset and the CULane dataset show that the proposed method achieves a good balance in speed and accuracy. On the CULane dataset, the reasoning speed is 1.13 times faster than UFLDv2 and the F1 score is improved from 74.7% to 77.1% compared with UFLDv2.

Keywords Computer vision, RepVGG, Lane detection, Curve fitting, Feature fusion, Post-processing

1 引言

近年来,随着人工智能的发展,自动驾驶技术也在蓬勃发展。车道线检测是自动驾驶的基本组成部分,是车辆车道保持的关键技术,同时也是环境感知的重要组成部分。尽管车道线检测已经取得了巨大的成功,但仍然存在检测速度慢、检测精度低等问题。

国内外研究可以分为基于传统方法的车道线检测和基于深度学习方法的车道线检测。基于传统方法的车道线检测方法^[1-3]依赖于人工提取的特征,且经验参数的选择对检测效果的影响较大。此类方法在简单场景中具有较好的识别效果,但在复杂场景中检测精度较低、鲁棒性较差,难以满足实际道路场景的应用需求。

最近,人工提取特征已经被深度学习^[4-7]提取特征所取代,这提高了车道检测的精度和鲁棒性。基于深度学习的车道线检测方法是目前车道线检测领域的研究热点,主要分为基于分割、分类和曲线模型 3 类。基于语义分割的方法^[8-12]精度较高且可以同时检测多个车道线,但由于需要对每个像素点进行分类,计算量较大。为了解决此问题,Hou 等^[13]通过自蒸馏的方法减小网络计算量,但本质上还是一种基于分割的方法,计算量仍然较大。

将车道线检测视为图像分类问题可以极大地提高检测速度,从而获得较高的实时性。Tian 等^[14]将车道线简化为点集,将输出划分为栅格,对栅格进行分类和回归分析。Qin 等^[15-16]将原始图像划分为栅格,通过行列分类问题判断车道线是否存在以及确定车道线存在的位置。Yoo 等^[17]将车道线

到稿日期:2023-04-18 返修日期:2023-09-20

基金项目:国家自然科学基金(61771085)

This work was supported by the National Natural Science Foundation of China(61771085).

通信作者:黄俊(huangjun@cqupt.edu.cn)

识别问题看作多行的分类任务,对每个车道线标记进行分类并以端到端的方式获得关键点。

此外,一些方法^[18-20]将车道线整体看作曲线处理,通常是一个高次多项式。虽然直接将车道线建模成曲线符合直觉且能够整体描绘车道线,但由于抽象的多项式系数很难学习,因此其性能远低于基于图像分类和图像分割的方法。综上,基于曲线模型的车道线检测方法虽然能从全局建模车道线,但检测精度相较于其他方法仍有差距;基于图像分割的车道线检测方法精度高,但计算量大,检测速度慢;基于图像分类的车道线检测方法精度与基于分割的方法相比,虽在检测速度方面有较大的提升,但牺牲了检测精度。

实时性是自动驾驶的关键指标之一,其直接影响车辆控制系统的响应速度,基于图像分类的车道线检测方式能够在多种场景下的检测任务,同时拥有较好的实时性。基于上述背景,本研究提出了一种轻量的车道线检测网络,将车道线检测视为图像分类问题,引入结构重参数化 VGG (structural re-parameterization VGG, RepVGG) 主干网络^[21]代替常用的残差网络 (Residual Network, ResNet) 主干网络^[22],从而提升模型的推理速度。此外,本文还通过融合不同层级的特征图来减少模型空间位置信息的丢失,提升模型对车道线的定位能力。针对车道线预测结果,本研究提出了一种简单有效的后处理方法:曲线建模车道线,从局部和整体两个角度修正车道线预测结果。最后,挖掘现有方法^[16]中车道线定位分支中的分布信息,提出基于分布指导的车道线存在预测分支,直接从车道线定位分布中学习车道线存在特征,进一步提升了模型表现。本文的主要贡献总结如下:

1) 提出了一种轻量的车道线检测网络,将车道线检测问题视为图像分类问题,并引入 RepVGG 主干网络来提升模型推理速度。

2) 通过不同层级的特征图的融合减少模型空间位置信息的丢失,提升模型对车道线的定位能力。

3) 提出了一种简单有效的后处理方法,通过曲线建模车道线,从局部和整体两个角度修正预测结果。

4) 提出了基于分布指导的车道线存在预测分支,通过挖掘现有方法中车道线定位分支中的分布信息,进一步提升了模型表现。

5) 在 CULane 和 TuSimple 数据集上进行实验评估,与多种基于深度学习的车道线检测算法的对比分析表明,本文提出的检测网络在检测速度和检测精度上取得了良好的平衡。

2 基于 RepVGG 网络的实时车道线检测方法

本章将介绍本研究的网络结构以及本文提出的改进方法,包括不同层级特征图融合、基于分布指导的车道线存在预测分支以及后处理方法。

2.1 网络结构

深度学习方法在车道线检测领域取得了巨大的成功,但是仍然存在一些重要和具有挑战性的问题需要解决。目前,车道线检测算法被广泛应用于资源受限的车载终端设备中,以提供即时感知结果,因此,实时性问题成为了亟需解决的问题。另一个就是在困难场景下的检测问题,特别是在极端光照或车道线被严重遮挡的场景下,检测模型需要拥有强大的

定位能力和全局信息感知能力以精准定位车道线和在困难场景下检测出车道线,同时还需要保证模型具有较高的实时性,这对车道线检测方法提出了较高的要求。

RepVGG 网络推理速度快、特征提取效果好,适用于对实时性要求较高的车道线检测任务。本研究使用轻量化的 RepVGG 版本作为主干。在 RepVGG 主干结构中引入特征图融合,以减少空间信息的丢失,提高模型对车道线的定位能力。将车道线检测视为行列方向的分类任务,以减少计算量,提高车道线检测速度。在后处理中曲线建模车道线,从全局和局部两个角度修正车道线检测结果,提升模型检测准确度。由车道线定位结果的输出的分布指导车道线存在预测,本文模型在略微提升模型速度的同时配合后处理方法进一步提升了模型表现。

本文提出的车道线检测方法如图 1 所示,主要由特征提取网络、车道线分类定位分支、车道线存在预测分支和后处理方法 4 部分组成。特征提取网络输出的特征图,经过全连接层后输入车道线分类定位分支,得到预测车道线位置。车道线分类定位分支假定所有车道线均存在,只负责定位车道线,不存在的车道线通过车道线存在预测分支滤除。对于不存在的车道线,车道线存在预测分支通过车道线分类定位分支结果中的分布信息判断车道线是否存在,滤除不存在的车道线。最后通过后处理对模型输出的车道线进行修正。后处理不参与模型推理过程,因此不会对模型推理速度造成影响。

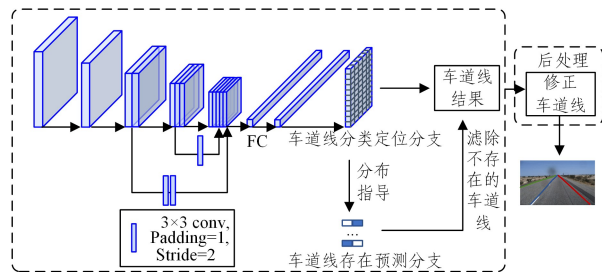


图 1 模型结构图

Fig. 1 Model structure

分类定位分支分为行分类定位分支和列分类定位分支两种,二者对车道线的定位方式相同,区别在于:行分类定位分支按行划分图片逐行定位车道线,而列分类定位分支按列划分图片逐列定位车道线。图 2 展示了行分类模式和列分类模式对不同角度的车道线表现出不同的性能。行分类模式适用于接近垂直的车道线,因为对于接近垂直的车道线,行分类模式拥有更多的定位点(如图 2 中第二列所示);而列分类模式则适用于接近水平的车道线。考虑到实际中车道线遵循中间车道线接近垂直、边缘车道线接近水平的规律,因此使用行分类定位分支来定位中间车道,使用列分类定位分支来定位边缘车道。




图 2 行分类模式和列分类模式的演示图

Fig. 2 Demonstration of row classification mode and column classification mode

以行分类定位分支为例,经过全连接层(Fully Connected Layer, FC)后,行分类定位分支输出为通道特征图(每个通道的特征图只负责定位一条车道线,因此特征图的通道数等于行分类分支预测的车道线数量)。每个通道特征图有 h^r 行 Row Anchor, 每个 Row Anchor 负责定位其在行的车道线位置,即对车道线逐行定位。将每个 Row Anchor 划分为 w^r 个栅格,车道线在 Row Anchor 的位置即是输出张量中响应最大的位置,从而车道线定位问题转变为了每个 Row Anchor 对 w^r 个栅格的分类问题。输出的车道线位置如式(1)所示。

$$\begin{aligned} Loc_{i,j}^r &= \arg \max_k (S_{i,j,k}) \\ \text{s. t. } & i \in [1, c^r], j \in [1, h^r], k \in [1, w^r] \end{aligned} \quad (1)$$

其中, S 为行分类定位分支中 Row Anchor 的输出张量; c^r 为行分类分支预测车道线的数量; h^r 为 Row Anchor 数量; w^r 为每个 Row Anchor 划分的栅格数量。输出的车道线位置演示如图 3 所示,首先逐行划分出 h^r 个 Row Anchor, 逐 Anchor 对车道线进行定位,将每个 Anchor 划分成 w^r 个栅格,车道线在 Anchor 中的位置就是响应最大的栅格所在位置,图中红色位置为演示的预测车道线所在栅格。




图 3 行分类预测车道线示意图(电子版为彩图)

Fig. 3 Row classification forecast lane

由于分类定位分支假设所有车道线均存在,只负责定位车道线,因此分类定位分支输出的车道线还需要通过车道线存在预测分支滤除不存在的车道线。以行分类定位分支为例,输出的车道线经过滤除后如式(2)所示:

$$\begin{aligned} Loc_{i,j}^r &= \begin{cases} \arg \max_k (S_{i,j,k}), & E_{i,j}^r = 1 \\ -1, & E_{i,j}^r = 0 \end{cases} \\ \text{s. t. } & i \in [1, c^r], j \in [1, h^r], k \in [1, w^r] \end{aligned} \quad (2)$$

其中, $E_{i,j}^r = 1$ 表示车道线存在预测分支判断车道线存在; $E_{i,j}^r = 0$ 表示车道线存在预测分支判断车道线不存在,车道线被滤除。列分类定位分支与行分类定位分支输出类似,将每个通道特征图分为 h^c 列 Column Anchor, 且行分类负责中心两车道的预测,列分类负责边缘两车道的预测。列分支最终输出的车道线如式(3)所示:

$$\begin{aligned} Loc_{i,j}^c &= \begin{cases} \arg \max_k (S_{i,j,k}), & E_{i,j}^c = 1 \\ -1, & E_{i,j}^c = 0 \end{cases} \\ \text{s. t. } & i \in [1, c^c], j \in [1, h^c], k \in [1, w^c] \end{aligned} \quad (3)$$

其中, $E_{i,j}^c = 1$ 表示车道线存在预测分支判断车道线存在; $E_{i,j}^c = 0$ 表示车道线存在预测分支判断车道线不存在,车道线被滤除; c^c 为列分类分支预测车道线数量; h^c 为 Column Anchor 数量; w^c 为每个 Column Anchor 划分的栅格数量。

行分类定位分支定位中间车道,列分类定位分支定位边缘车道,将两者输出融合得到全部车道线位置预测结果。推理过程如图 4 所示,车道线分类定位分支假定所有车道线均存在,预测结果经过车道线存在预测分支滤除不存在的车道线

(图 4 中紫色车道线和绿色车道线部分)后得到模型输出的车道线预测结果。最后模型输出的车道线预测结果经过后处理进行修正。

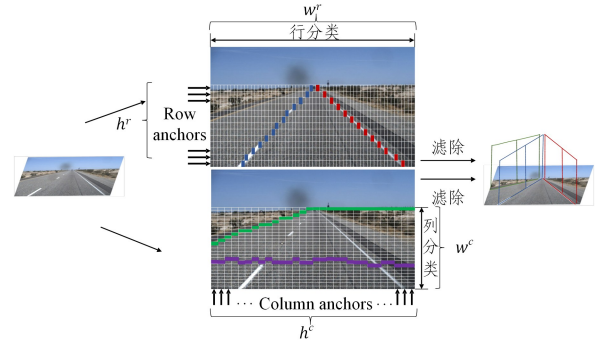


图 4 行列分类预测车道线图(电子版为彩图)

Fig. 4 Row and column classification forecast lane

2.2 主干网络的改进

本文使用 RepVGG 网络作为主干网络,其中, RepVGG 在训练时将 VGG^[23] 网络的 3×3 卷积扩张为 3×3 卷积、 1×1 卷积和残差连接的多分支模型结构以提升网络的特征提取能力,训练完成后使用结构重参数化 (Structural Re-parameterization) 将多分支模型结构融合为单路模型结构,在加快网络推理速度的同时没有任何精度损失。RepVGG 网络训练时模型结构和推理时模型结构的部分表达如图 5 所示。




图 5 RepVGG 网络训练时和推理时模型结构的部分表达图

Fig. 5 RepVGG network model structure during training and inference

在车道线检测过程中,需要对车道线进行定位,保持位置空间信息,从而有效提高定位精度。浅层特征图分辨率更高,包含更多位置信息,但由于卷积次数少,其语义性较差且噪声更多。高层特征具有更强的语义信息,但损失了位置信息,对细节的感知能力较差。因此,本研究将不同层级的特征图进行融合,以得到更丰富的特征表示,其中既包含了浅层特征图的位置信息,也包含了高层特征图的语义信息。通过跨步卷积将 RepVGG 主干网络中最后 3 个阶段的输出特征缩放到统一的最后一阶段的特征图尺寸。通过跨步卷积减少特征图尺寸相较于最大池化保留了更多的位置信息。接下来,将缩放后的特征图进行堆叠融合,作为后续全连接层的输入。

2.3 基于分布指导的车道线存在预测分支

对于车道线存在情况的预测,目前同类车道线检测方法^[15]将车道线分类定位和车道线存在预测视为两个独立的任务,存在 3 个问题:1)未利用车道线分类任务和车道线存在

预测任务之间的关联性;2)未利用车道线分类定位分支输出张量的分布信息;3)车道线分类定位分支和车道线存在预测分支均从特征图的全局采集信息,导致了没有必要的计算开销。

车道线分类定位分支输出张量的分布信息示例如图 6 所示,可以看出车道线分类定位分支的输出分布与车道线是否存在具有很强的相关性:在车道线存在的位置,车道线分类定位分支的输出陡峭,呈现山峰形状;在车道线不存在的位置,车道线分类定位分支的输出平缓。




图 6 车道线分类定位分支的分布信息示意图

Fig. 6 Distribution information of classification and positioning branches of lane lines

本研究利用车道线分类定位分支中与车道线之间是否存在强相关性,提出了基于分布指导的车道线存在预测分支,使用车道线分类定位分支输出张量的分布来预测车道线是否存在。以列分类定位分支为例,如图 6 所示,车道线存在预测分支直接从定位结果的某一列判断车道线是否存在,避免采集特征图的全局信息,同时,我们利用车道线定位任务并判断车道线是否存在任务的相关性,在降低计算开销的同时还提升了模型表现。受注意力机制 SENet^[24]的启发,本文还提出了分类定位注意力模块(CLSE)嵌入车道线预测存在分支。如图 7 所示,输入 CLSE 模块的是车道线分类定位结果,CLSE 模块使模型对不同的分类栅格给予不同的关注程度。




图 7 分类定位注意力模块结构图

Fig. 7 Structure of classification and localization attention module

本文提出的基于分布指导的车道线存在预测分支如图 8 所示。图中的 \mathbf{X} 为分类定位分支的输出,分类定位信息经过 3 个全连接层提取分类定位输出信息判断车道线是否存在,在全连接中插入 CLSE 模块以提高信息提取能力。这个过程可以表示为:

$$\mathbf{Y} = \text{FC}(\text{FC}(\text{CLSE}(\text{FC}(\text{CLSE}(\mathbf{X})))))) \quad (4)$$

其中, \mathbf{X} 为输入的分类定位特征矩阵, \mathbf{Y} 为输出车道线存在信息,FC 为全连接层,CLSE 为分类定位注意力模块。




图 8 基于分布指导的车道线存在预测分支图

Fig. 8 Prediction branch of lane based on distributed guidance

2.4 后处理方法

由于现实中的车道线可以使用高次曲线建模,因此预测良好的车道线应该与其拟合出的高次曲线具有如下关系:从局部角度考虑,车道线与其拟合的曲线在位置上应当非常接近;从整体角度考虑,拟合的车道线与预测的车道线应当非常匹配。所提出的后处理方法从局部和整体两个角度出发对模型的预测结果进行修正,具体如下:在局部修正方面,针对车道线某些与高次曲线相差较远的位置进行处理,用高次曲线对应的位置替代某些预测结果偏差较大的位置,从而实现局部的修正。因此,预测效果差的部分可以通过修正共享预测良好的结果。对车道线的局部修正如式(5)所示:

$$Loc_{i,j} = \begin{cases} Loc_{i,j}^f, & |Loc_{i,j} - Loc_{i,j}^f| > T \\ Loc_{i,j}, & \text{otherwise} \end{cases} \quad (5)$$

其中, $Loc_{i,j}^f$ 为高次曲线拟合出的车道线位置; $Loc_{i,j}$ 为高次曲线拟合出的车道线位置,采用二次曲线进行拟合; T 为偏差的阈值,设置为 10。

在整体修正方面,如果某条车道线是正确预测的车道线,那么其应该与拟合出的高次曲线匹配,反之则表示此车道线是误预测的车道线,应该被滤除。采用二次曲线使用最小二乘法对车道线进行拟合,将拟合残差平方和大于阈值的车道线视为误预测的车道线,将其滤除,阈值设置为 100。

局部角度和整体角度修正车道线的可视化如图 9 所示,前两行是整体角度滤除车道线的结果,后两行是局部角度修正车道线的结果。可见,所提出的后处理方法能局部修正预测效果差的部分车道线,也能整体滤除错误预测的车道线。




图 9 局部和整体角度修正车道线可视化图

Fig. 9 Visualization of local and global lane line correction

2.5 损失函数

行列分类定位分支和车道线存在预测分支分别使用交叉熵损失函数计算分类误差。

车道线分类定位分支的损失 L_{cls} 定义为:

$$L_{cls} = \sum_{i=1}^{N_{line}^r} \sum_{j=1}^{N_{row}^r} L_{CE}(P_{i,j}^r, \text{onehot}(T_{cls,i,j}^r)) + \sum_{m=1}^{N_{line}^c} \sum_{n=1}^{N_{col}^c} L_{CE}(P_{m,n}^c, \text{onehot}(T_{cls,m,n}^c)) \quad (6)$$

其中, L_{CE} 是交叉熵损失函数; $P_{i,j}^r$ 是行列分类模式预测的第 i 条车道线的第 j 个 Row Anchor 的预测结果, $T_{cls,i,j}^r$ 是其对应的分类标签; $P_{m,n}^c$ 是列分类模式预测的第 m 条车道线的第 n 个 Column Anchor 的预测结果, $T_{cls,m,n}^c$ 是其对应的分类标签; onehot 是独热编码函数。

车道线存在预测分支的损失 L_{ext} 定义为:

$$L_{ext} = \sum_{i=1}^{N_{line}^r} \sum_{j=1}^{N_{row}^r} L_{CE}(E_{i,j}^r, \text{onehot}(T_{ext,i,j}^r)) + \sum_{m=1}^{N_{line}^c} \sum_{n=1}^{N_{col}^c} L_{CE}(E_{m,n}^c, \text{onehot}(T_{ext,m,n}^c)) \quad (7)$$

其中, $E_{i,j}^r$ 和 $E_{m,n}^c$ 是车道线存在预测分支的预测结果; $T_{ext,i,j}^r$ 和 $T_{ext,m,n}^c$ 是对应的标签。

最后给出总的损失函数, 如式(8)所示:

$$Loss_{total} = L_{cls} + \alpha L_{ext} \quad (8)$$

其中, L_{cls} 为行列分类定位分支的损失; L_{ext} 为车道线存在预测分支的损失; α 为车道线存在预测分支损失的系数, 设置为 10。

3 实验与结果分析

本章详细介绍了实验设置、对比实验和数据集上的结果。

3.1 实验设置

3.1.1 数据集

为了评估模型效果, 本文在两个广泛使用的数据集, 即 TuSimple 数据集和 CULane 数据集^[25] 上进行实验。TuSimple 数据集收集高速路上的稳定照明场景, 由视频片段 (clip) 组成。由于一个 clip 中只有最后一帧有标注, 因此只对最后一帧进行训练和测试。CULane 数据集由 9 种不同的场景组成, 包括正常、拥挤、夜晚、无车道线、阴影、箭头、炫光、弯道和交叉路口。数据集的详细信息如表 1 所列。

表 1 数据集信息

Table 1 Dataset information

数据集	数量	训练集	验证集	测试集	分辨率	车道线数量	场景	环境
TuSimple	6408	3268	358	2782	1280×720	小于等于 5	1	高速路
CULane	133235	88880	9675	34680	1640×590	小于等于 4	9	城市和高速路

3.1.2 度量指标

TuSimple 数据集和 CULane 数据集的官方度量标准不同。TuSimple 数据集使用准确度作为度量指标, 计算公式为:

$$accuracy = \frac{\sum_{clip} C_{clip}}{\sum_{clip} S_{clip}} \quad (9)$$

其中, C_{clip} 为一个 clip 的最后一帧中正确预测车道线点的数量, S_{clip} 为一个 clip 的最后一帧中真实的车道线点标注的总数。CULane 数据集使用 F1-measure 作为度量指标, 计算公式为:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (10)$$

其中, $Precision = \frac{TP}{TP+FP}$, $Recall = \frac{TP}{TP+FN}$, FP 和 FN 代表假阳和假阴。在 TuSimple 数据集上, 除了采用准确度作为度量指标, 还采用了 CULane 数据集的评价指标。

3.1.3 训练设置

本实验基于 Ubuntu 20.04 操作系统, 使用 PyTorch 框架搭建环境, 显卡为 NVIDIA GTX 1080Ti。不同数据集的具体设置如表 2 所列。使用 SGD 优化器, 学习率设置为 0.005, 学习率衰减方式为多步长衰减, 训练总轮数为 65。

表 2 不同数据集的训练设置

Table 2 Training settings of different datasets

数据集	训练分辨率	c^r	h^r	w^r	c^c	h^c	w^c
TuSimple	800×320	2	56	100	2	40	100
CULane	1600×320	2	18	200	2	40	100

3.2 消融实验

在本节中, baseline 为基于 ResNet-18 的 UFLD-v2

模型^[16]。为了比较更公平, 本文在相同的条件下重新测试了 baseline 的速度。

首先, 如表 3 所列, 根据速度和 F1 分数对本文提出的改进点进行评估。将主干网络切换为 RepVGG 后, 由于两个网络的特征提取能力相似, 模型准确率没有提升, 甚至略有下降, 同时由于 RepVGG 解耦前的多分支结构, 模型推理速度由 135 FPS 下降到 118 FPS。在融合不同层级的特征图之后, 模型学习到了更丰富的特征表示, F1 分数提升了 1%, 但速度略有下降。加入后处理方法后, 模型 F1 分数进一步提升 1.2%, 证明了所提出的后处理方法对模型预测结果优秀的修正能力, 且后处理对模型推理速度没有影响。相较于 baseline 模型, 所提出的车道线存在预测分支关联了车道线定位任务和判断车道线存在任务, 使两个任务相互促进, 因此加入车道线存在预测分支后模型 F1 分数进一步提升到 77.1%, 同时, 由于避免了从特征图全局采集信息, 因此推理速度没有降低, 反而略有提高。最后展示了 RepVGG 解耦后的模型表现, 相较于 baseline 模型, 解耦后的模型的推理速度由 135 FPS 提升到 152 FPS, F1 分数由 74.7% 提升到 77.1%。

表 3 CULane 数据集上的消融实验

Table 3 Ablation experiments on CULane dataset

Baseline	Rep-VGG-解耦前	Rep-VGG-解耦后	高低特征图融合	后处理方法	车道线存在预测分支	F1 分数/%	速度/FPS
✓						74.7	135
	✓					74.5	118
		✓				75.5	105
			✓			76.7	105
				✓		77.1	106
					✓	77.1	152

3.3 模型对比

本节展示了在 TuSimple 与 CULane 数据集上本文模型与其他模型的性能比较。

对于 TuSimple 数据集,使用了 7 种模型与本文模型进行比较,包括:SCNN^[25], LaneNet^[11], EL-GAN^[26], SAD^[13], FastDraw^[27], LaneATT^[28], UFLDv2^[16]。在实验中比较了不同模型的 F1 分数和速度,结果如表 4 所列。可以看出,本文模型在推理速度方面达到了最佳性能。与同类方法 UFLDv2 相比,F1 分数低了 0.03%,但推理速度是其 1.13 倍。

表 4 在 TuSimple 测试集上不同模型的 F1 分数、准确率及其实时性比较

Table 4 Performance comparison of different models on TuSimple test set

方法	F1 分数/%	准确率/%	实时性/ms	速度
SCNN ^[25]	95.97	96.53	133.5	1.0×
LaneNet ^[11]	94.80	96.38	19.0	7.0×
EL-GAN ^[26]	96.26	94.90	大于 100	小于 1.3×
SAD ^[13]	95.92	96.64	13.4	10.0×
FastDraw ^[27]	93.92	95.20	11.1	12.0×
LaneATT (ResNet-18) ^[28]	96.71	95.57	4.0	33.4×
LaneATT (ResNet-34) ^[28]	96.77	95.63	5.9	22.6×
UFLDv2 (ResNet-18) ^[16]	96.16	95.65	3.2	41.7×
OURS	96.13	95.47	2.8	47.0×

对于 CULane 数据集,在交并比 (Intersection over Union, IoU) 为 0.5 的条件下,使用了 7 种模型与本文模型进行比较,包括:SCNN^[25], SAD^[13], LaneATT^[28], RESA^[29], SGNet^[30], FOLOLane^[31], UFLDv2^[16]。测试结果如表 5 所列,使用 F1 分数评估总体和子场景(除交叉路口外),对于交叉路口场景,使用假阳性进行评估,因为该场景没有车道线。相对于 TuSimple 数据集,CULane 数据集的场景更加多样复杂。对于炫光、阴影和夜晚场景,由于光线过强或不足,图像的细节信息难以捕捉,模型的特征提取能力下降。对于拥挤和无车道线场景,由于车道线存在遮挡和模糊的情况,因此车道线特征提取困难,模型精度下降严重。本文模型在推理速度方面达到了最佳性能。与同样基于分类检测车道线的轻量版 UFLDv2(ResNet-18)相比,本文模型在所有场景上表现均有提升(炫光场景 F1 分数高出 4.6%);与 UFLDv2(ResNet-34)相比,在速度达到其 2.26 倍的同时 F1 分数仍比其高 1.2%。虽然与 FOLOLane 相比本文模型的 F1 分数低 1.7%,但本文模型的推理速度是其 9.3 倍。

最后展示了在 TuSimple 和 CULane 数据集上的可视化结果。如图 10 所示,前三行为 TuSimple 数据集可视化结果,后三行为 CULane 数据集可视化结果。本文模型可以准确地预测出车道线位置,且可以正确判断并滤除不存在的车道线。此外,从实车中随机抽取图片进行检测,如图 11 所示,车道线检测数量与形状与实际情况相符,检测效果良好。

表 5 CULane 测试集上不同模型各场景 F1 分数、总 F1 分数及其实时性比较

Table 5 Comparison of F1-measure and runtime on CULane test set

方法	正常场景 F1 分数/%	拥挤场景 F1 分数/%	炫光场景 F1 分数/%	阴影场景 F1 分数/%	无车道线 场景 F1 分数/%	箭头场景 F1 分数/%	弯道场景 F1 分数/%	交叉路口 假阳性	夜晚 场景 F1 分数/%	总 F1 分数/%	实时性/ FPS	速度
SCNN ^[25]	90.6	69.7	58.5	66.9	43.4	84.1	64.4	1990	66.1	71.6	8	1.0×
SAD ^[13]	90.1	68.8	60.2	65.9	41.6	84.0	65.7	1998	66.0	70.8	75	9.4×
RESA	91.9	72.4	66.5	72.0	46.3	88.1	68.6	1896	69.8	74.5	45	5.6×
(ResNet-34) ^[29]	92.1	73.1	69.2	72.8	47.7	88.3	70.3	1503	69.9	75.3	36	4.5×
RESA	91.1	72.9	65.7	70.9	48.3	85.4	63.3	1170	68.9	75.1	250	31.3×
(ResNet-18) ^[28]	92.1	75.0	66.4	78.1	49.3	88.3	67.7	1330	70.7	76.6	171	21.4×
LaneATT	91.4	74.0	66.8	72.1	50.1	87.1	67.0	1164	70.6	76.1	117	14.6×
(ResNet-34) ^[28]	92.7	77.8	75.2	79.3	52.1	89.0	69.4	1569	74.5	78.8	40	5.0×
SGNet ^[30]	91.7	73.0	64.6	74.7	47.2	87.6	68.7	1998	70.2	74.7	330	41.3×
UFLDv2 (ResNet-18) ^[16]	92.5	74.9	65.7	75.3	49.0	88.5	70.2	1864	70.6	75.9	165	20.6×
UFLDv2 (ResNet-34) ^[16]	92.3	75.0	69.2	75.7	50.0	89.2	69.5	1425	72.3	77.1	372	46.5×
OURS												

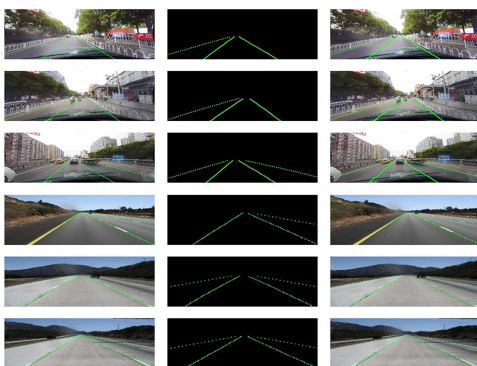


图 10 CULane 数据集和 TuSimple 数据集可视化图
Fig. 10 Visualization of CULane and TuSimple datasets




图 11 实车检测效果图

Fig. 11 Real vehicle detection result

结束语 本文针对现有车道线检测算法存在的检测精度低、检测速度慢的问题,基于分类的车道线检测方式,提出了一种基于 RepVGG 网络的实时车道线检测网络。首先,在主干网络中融合高低层特征图,减少空间信息损失,提高模型定位精度。其次,通过曲线建模车道线,从局部和全局两个角度修正车道线预测结果。最后,提出基于分布指导的车道线

存在检测分支,结合所提出的后处理方法,在不影响模型推理速度的同时提高了模型检测精度。实验结果表明,本文提出的算法在精度与实时性上达到了平衡,与同类最优方法相比,推理速度达到其 1.13 倍,同时,评价指标 F1 分数由 74.7% 提高到 77.1%。

未来的工作拟更高效地提取特征,动态设置分类栅格数量以提高检测精度。

参 考 文 献

- [1] JIANG Y, GAO F, XU G. Computer vision-based multiple-lane detection on straight road and in a curve[C]// 2010 International Conference on Image Analysis and Signal Processing. IEEE, 2010: 114-117.
- [2] HU H D, LIU G R, WNG L L, 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] JUNG H, MIN J, KIM J. An efficient lane detection algorithm for lane departure detection[C]// 2013 IEEE Intelligent Vehicles Symposium(IV). IEEE, 2013: 976-981.
- [4] WANG Q, HAN T, QIN Z, et al. Multitask attention network for lane detection and fitting[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 33(3): 1066-1078.
- [5] QIU Q, GAO H, HUA W, et al. PriorLane: A Prior Knowledge Enhanced Lane Detection Approach Based on Transformer[J]. arXiv: 2209.06994, 2022.
- [6] 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, 2022, 24(3): 3448-3460.
- [7] ZHENG T, HUANG Y, LIU Y, et al. Clrnet: Cross layer refinement network for lane detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 898-907.
- [8] 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, 2017, 40(4): 834-848.
- [9] DONG Y, PATIL S, VAN AREM B, et al. A hybrid spatial-temporal deep learning architecture for lane detection [J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 38(1): 67-86.
- [10] HOU Y. Agnostic lane detection [J]. arXiv: 1905.03704, 2019.
- [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, IV. Changshu: Institute of Electrical and Electronics Engineers Inc., 2018: 286-291.
- [12] YANG J, ZHANG L, LU H. Lane Detection with Versatile AtrousFormer and Local Semantic Guidance[J]. Pattern Recognition, 2023, 133: 109053.
- [13] HOU Y, MA Z, LIU C, et al. Learning lightweight lane detection CNNs by self attention distillation[C]// 17th IEEE/CVF International Conference on Computer Vision. Seoul: Institute of Electrical and Electronics Engineers Inc., 2019: 1013-1021.
- [14] 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.
- [15] QIN Z, WANG H, LI X. Ultra fast structure-aware deep lane detection[C]// European Conference on Computer Vision. Glasgow: Springer, 2020: 276-291.
- [16] QIN Z, ZHANG P, LI X. Ultra Fast Deep Lane Detection With Hybrid Anchor Driven Ordinal Classification [J]. arXiv: 2206.07389, 2022.
- [17] YOO S, SEOK L H, MYEONG H, et al. End-to-end lane marker detection via row-wise classification[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Virtual: IEEE Computer Society, 2020: 4335-4343.
- [18] FENG Z, GUO S, TAN X, et al. Rethinking Efficient Lane Detection via Curve Modeling[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). New Orleans: IEEE, 2022: 17041-17049.
- [19] HAN J, DENG X, CAI X, et al. Laneformer: Object-aware Row-Column Transformers for Lane Detection[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2022: 799-807.
- [20] TABELINI L, BERRIEL R, PAIXAO T M, et al. PolyLaneNet: Lane Estimation via Deep Polynomial Regression [C] // 2020 25th International Conference on Pattern Recognition (ICPR). Milan, Italy: IEEE, 2021: 6150-6156.
- [21] DING X, ZHANG X, MA N, et al. RepVgg: Making VGG-style ConvNets Great Again[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Virtual: IEEE Computer Society, 2021: 13728-13737.
- [22] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2016: 770-778.
- [23] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// 3rd International Conference on Learning Representations (ICLR). San Diego, 2015.
- [24] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-Excitation Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42(8): 2011-2023.
- [25] PAN X, SHI J, LUO P, et al. Spatial as deep: Spatial CNN for traffic scene understanding[C]// 32nd AAAI Conference on Artificial Intelligence. New Orleans: AAAI press, 2018: 7276-7283.
- [26] GHAFORIAN M, NUGTEREN C, BAKA N, et al. EL-GAN: Embedding Loss Driven Generative Adversarial Networks for Lane Detection [C] // 15th European Conference on Computer Vision. Munich: Springer, 2018: 256-272.
- [27] PHILION J. FastDraw: Addressing the long tail of lane detection by adapting a sequential prediction network [C] // 32nd IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 11574-11583.
- [28] TABELINI L, BERRIEL R, PAIXAO T M, et al. Keep your

Eyes on the Lane: Real-time Attention-guided Lane Detection [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Virtual; IEEE Computer Society, 2021: 294-302.

[29] ZHENG T, FANG H, ZHANG Y, et al. RESA: Recurrent Feature-Shift Aggregator for Lane Detection [C] // 35th AAAI Conference on Artificial Intelligence. Virtual; Association for the Advancement of Artificial Intelligence, 2021: 3547-3554.

[30] SU J, CHEN C, ZHANG K, et al. Structure Guided Lane Detection [C] // 30th International Joint Conference on Artificial Intelligence. 2021: 997-1003.

[31] QU Z, JIN H, ZHOU Y, et al. Focus on local : Detecting lane marker from bottom up via key point [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Virtual; IEEE Computer Society, 2021: 14122-14130.



CAI Wenliang, born in 1999, postgraduate. His main research interests include object detection and deep learning.



HUANG Jun, born in 1971, Ph.D, professor, master supervisor. His main research interests include object detection and deep learning.

(责任编辑:何杨)

企业架构引领数字化转型 | TF135 回顾

1.《业务架构方法与发展新趋势》

来自北京天润聚粮咨询服务有限公司执行董事总经理付晓岩分享的主题是《业务架构方法与发展新趋势》,他详细介绍了业务架构的方法与发展新趋势,包括业务架构的定义、作用、设计方法等,强调业务架构是企业架构的核心,是连接业务与技术的桥梁,是解决企业 IT 治理、业技融合和整体转型问题的关键,强调了全局性结构化思维在数字化时代的必要性。他提出,数据作为新的生产要素,使得软件成为企业最重要的生产工具。在分享中,付晓岩提到:“业务架构是贯穿企业战略和 IT 实现的切入点,它包含‘产品、流程、实体’3 种基础模型和‘领域、组件、对象’3 个业务层次,通过‘五步方法论’来实现”,“业务架构设计的最终结果,它是一个业务能力的布局”,“从架构角度去看数字化应用实现的部分对业务架构的覆盖程度越大,你的数字化的实现就越好,或者说实现就越完整”这些洞见充分体现了业务架构在企业数字化转型中的核心地位。

2.《应用架构助力企业跨越数字化转型周期》

企业架构和应用架构领域专家王言以《应用架构助力企业跨越数字化转型周期》为题,回顾了企业数字化转型的发展历程,介绍了应用架构在企业数字化转型中的重要作用。通过类比城市规划和建筑发展,形象地阐述了应用架构在企业数字化转型中的重要性 and 复杂性。他提到了应用架构不仅仅是一套方法论,而是一个持续的过程,需要随着时间的推移不断地演进和优化。讲解了应用架构的核心关键能力,包括继承 IT 战略、与业务架构紧密关联、对向下的指导等。分享了应用架构跨越数字化转型周期的方法和策略,包括确定老应用是否需要迁移、采用不同的迁移策略等。王言特别强调了技术债务的管理,这是确保应用架构健康发展的关键,区分了技术债务的四个象限,以及对应的管理策略。

他提出:“企业架构的转型应当从应用架构的迁移改造开始,逐步偿还技术债,适应数字化转型的需求”。王言强调了应用架构在企业转型中的作用,通过不断优化应用架构,企业可以更好地支持数据的产生、存储、流转和合理的数据标准,进而推动数字经济的发展。他提到:“应用架构的工作是 IT 人士最基础的工作,它帮助我们逐步解决累积的问题,适应数字化转型的要求。”

3.《企业架构从应用优先到数据优先》

数字产业创新研究中心副主席,《精益数据方法论》作者史凯分享了《企业架构从应用优先到数据优先》,阐述了数据在企业软件应用过程中的四个阶段,以及数据如何成为业务的新型存在形式。强调企业正在走向九龙治水到数据驱动全局优化的过程,数据的重要性日益凸显。分享了大模型时代,传统架构模式正在坍塌,企业架构从应用优先走向数据优先。大模型和人工智能的发展将颠覆传统的数据价值链,企业需要适应这种变化,利用数据驱动业务增长和提升效率。

他提出“数据永生,应用快速迭代”,“数据已经成为了业务的存在形式”,“每个企业都会构建自己的数据资产蓝图和场景蓝图,数字化技术将聚焦于如何使用数据,企业将逐渐从人的驱动、流程的驱动转向数据的驱动”,“用全局的优化替代局部的优化”,这表明在数字化时代,数据作为新的生产要素,已经成为业务的核心载体。未来的企业将不再需要复杂的界面,而是通过数据和算法直接驱动业务流程。

在活动最后的问答环节中,TF 数字化转型与企业架构 SIG 主席史海峰作为主持人,与三位讲者讨论了在线参会者提出的关于业务本质是不是数据、AI 平台与架构的区别、企业架构实施的时机以及如何调动业务部门参与架构设计的积极性等问题。