

文章编号 2097-1842(2023)03-0645-09

基于双注意力机制的车道线检测

任凤雷^{1,2}, 周海波^{1,2*}, 杨璐^{1,2}, 何昕³

1. 天津理工大学机械工程学院 天津市先进机电系统设计与智能控制重点实验室, 天津 300384;
2. 天津理工大学机电工程国家级实验教学示范中心, 天津 300384;
3. 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033)

摘要: 为了提升车道线检测算法在障碍物遮挡等复杂情况下的检测性能, 本文提出了一种基于双注意力机制的多车道线检测算法。首先, 本文通过设计基于空间和通道双注意力机制的车道线语义分割网络, 得到分别代表车道线像素和背景区域的二值分割结果; 然后, 引入 HNet 网络结构, 使用其输出的透视变换矩阵将分割图转换为鸟瞰视图, 继而进行曲线拟合并逆变换回原图像空间, 实现多车道线的检测; 最后, 将图像中线两侧车道线所包围的区域定义为目前行驶的行车车道。本文算法在 Tusimple 数据集凭借 134 frame/s 的实时性表现达到了 96.63% 的准确率, 在 CULane 数据集取得了 77.32% 的精确率。实验结果表明, 本文算法可以针对包括障碍物遮挡等不同场景下的多条车道线及行车车道进行实时检测, 其性能相比较现有算法得到了显著的提升。

关键词: 车道线检测; 语义分割; 注意力机制; 车道线拟合

中图分类号: TP394.1 文献标志码: A doi: 10.37188/CO.2022-0033

Lane detection based on dual attention mechanism

REN Feng-lei^{1,2}, ZHOU Hai-bo^{1,2*}, YANG Lu^{1,2}, HE Xin³

1. Tianjin Key Laboratory for Advanced Mechatronic System Design and Intelligent Control, School of Mechanical Engineering, Tianjin University of Technology, Tianjin 300384, China;
2. National Demonstration Center for Experimental Mechanical and Electrical Engineering Education, Tianjin University of Technology, Tianjin 300384, China;
3. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

* Corresponding author, E-mail: haibo_zhou@163.com

Abstract: In order to improve the performance of lane detection algorithms under complex scenes like obstacles, we proposed a multi-lane detection method based on dual attention mechanism. Firstly, we designed a lane segmentation network based on a spatial and channel attention mechanism. With this, we obtained a binary image which shows lane pixels and the background region. Then, we introduced HNet which

收稿日期: 2022-03-04; 修订日期: 2022-04-06

基金项目: 天津市自然科学基金重点项目 (No. 17JCZDJC30400); 广东省重点领域研发计划项目 (No. 2019B090922002)

Supported by Key projects of Tianjin Natural Science Foundation (No. 17JCZDJC30400); Special Project for Research and Development in Key Areas of Guangdong Province (No. 2019B090922002)

can output a perspective transformation matrix and transform the image to a bird's eye view. Next, we did curve fitting and transformed the result back to the original image. Finally, we defined the region between the two-lane lines near the middle of the image as the ego lane. Our algorithm achieves a 96.63% accuracy with real-time performance of 134 FPS on the Tusimple dataset. In addition, it obtains 77.32% of precision on the CULane dataset. The experiments show that our proposed lane detection algorithm can detect multi-lane lines under different scenarios including obstacles. Our proposed algorithm shows more excellent performance compared with the other traditional lane line detection algorithms.

Key words: lane detection; semantic segmentation; attention mechanism; lane fitting

1 引言

自2020年伊始,“新基建”逐渐走入大众视野,其全称为新型基础设施建设,其中,智能交通系统作为其中极具代表性的计划之一,引起了愈发广泛的关注和重视。近来,众多科研学者致力于研发半自动或全自动驾驶技术,使其得到了飞速的发展和突破。其中,车道线检测是自动驾驶系统(Autonomous driving system)以及高级驾驶辅助系统(Advanced Driver Assistance Systems, ADASs)中最基础,也是极为关键的技术。车道线通常定义为用来分隔两行车车道的线,通常以车道标记的形式出现在道路上。车道线检测可以给出道路中车道线的准确位置及形状,其对自动驾驶汽车判断自身在道路中的具体位置和行驶状态,进而实现车道保持及变道行驶等功能具有极为重要的意义^[1-4]。

近年来,受益于人工智能以及机器学习等技术的快速发展,很多基于图像的车道线检测算法被相继提出。在深度学习技术得到广泛应用前,大部分传统的车道线检测算法通常依赖于手工提取的纹理、颜色等特征并结合后处理步骤来进行算法设计。如Sobel, Canny等常用的边缘检测算法经常被应用于检测车道线的边界。Chiu K Y等人^[5]提出了一种基于颜色信息的车道线检测算法,该算法首先选择图像中的感兴趣区域(Region Of Interest, ROI),然后通过检测车道线的边缘实现对车道线的检测。Hur J等人^[6]提出使用条件随机场(Conditional Random Fields, CRFs)检测车道线等车道标记。Jung H等人^[7]基于图像传感器安装于车辆中心位置的假设,通过提取候选点实现了车道偏离预警。Borkar A等人^[8]提出了一种基于图像视频序列的夜间车道检测算法。

随着深度学习技术的突飞猛进,深度神经网络被愈发广泛地应用于车道线检测算法的设计。卷积神经网络(Convolutional Neural Network, CNN)极为突出的图像特征提取能力,使得车道线检测算法的性能得到了空前的提升。如De Brabandere B等人^[9]提出了一种端到端的车道线检测算法。该算法主要包含两个部分,前者用于检测车道线区域,后者使用最小二乘法拟合车道线模型。Liu T等人^[10]利用生成式对抗网络(Generative Adversarial Networks, GANs)实现了弱光照极端条件下的车道线检测。Chang D等人^[11]提出通过使用实例分割的方法并引入无监督投票机制实现车道线的检测。Kim J等人^[12]提出通过同时使用CNN和RANSAC(Random Sample Consensus)完成车道线检测任务。Neven D等人^[13]提出将车道线的检测任务看作一个实例分割问题,继而设计包含车道分割分支和车道嵌入分支的实例分割网络并进行端到端的训练,最终完成了车道线检测任务。

尽管深度学习技术的引入使得基于视觉的车道线检测算法性能得到了前所未有的提升,但现有的车道线检测算法仍然存在着如下问题:首先,车道线检测算法的准确性及鲁棒性不足,尤其是在车辆等障碍物遮挡的情况下,现有算法受到网络局部感受野的限制,导致网络推理能力不足,难以准确检测到车道线的位置。其次,车道线检测任务对实时性要求较高,但大部分车道线检测算法通常使用复杂的深度网络提取图像特征,导致实时性难以满足实际应用需求。此外,很多车道线检测算法都预定义了固定数量的两条车道线,因此无法同时针对多条车道线进行检测,导致车辆无法应对变道行驶的特殊情况^[14-15]。

针对上述问题,本文提出了一种基于双注意力机制的多车道线检测算法。首先,为了对多条

车道线同时进行检测, 本文设计了车道线分割网络, 同时为了增强网络在障碍物遮挡情况下的推理能力, 提高车道线检测算法的准确性和鲁棒性, 本文在特征提取网络的基础上引入了空间和通道双注意力机制, 从而将输入图像分割成分别代表车道线像素和背景区域的二值分割图; 其次, 在上述基础上引入 HNet 进行车道线拟合, 最终完成对多车道线的检测及对车辆目前行驶的行车车道的确认, 以使车辆可以应对变道行驶的问题; 此外, 本文算法在特征提取阶段借鉴了轻量级的 ResNet-18 网络模型结构, 可以保证车道线检测算法的实时性。

2 相关工作

2.1 车道线检测

行车车道线是最为基本也是极为重要的交通标志。基于视觉的车道线检测的主要目的是从输入的交通环境图像中输出车道线所在的位置及其数学模型表示。其示意图如图 1 所示。



图 1 车道线检测示意图

Fig. 1 Schematic diagram of lane detection

2.2 语义分割

图像语义分割是计算机视觉领域的一项基础任务, 其目标是针对图像像素进行类别预测, 进而将输入图像分割成多个区块, 使得图像中的每个像素都与一个目标类型相关联。也就是说, 经过

语义分割的输出图像的每一个像素都对应着其特有的语义类别。其示意图如图 2(彩图见期刊电子版)所示。



图 2 图像语义分割示意图

Fig. 2 Schematic diagram of semantic segmentation of image

2.3 注意力机制

注意力机制(Attention Mechanism)最初被用于机器翻译。针对视觉任务, 通过融入注意力机制可以引导网络主动捕获有效的特征而忽略不相关的特征, 并已经在包括检测、识别、分割等多个视觉任务中提升了算法的性能。注意力机制实质上是一种对资源进行自动重新分配的机制, 即将对于神经网络平均分配资源的形式通过融入网络注意力调整为针对特征的不同重要程度赋予不同的权重, 从而突出对任务更加重要的特征^[6]。

3 本文算法

结合上述车道线检测和图像语义分割任务的相关性, 本文算法拟借鉴图像语义分割的思路, 通过设计基于双注意力机制的图像语义分割网络将输入图像分割为车道线像素区域和背景区域两种语义类别, 继而对分割得到的车道线像素进行车道线拟合并实现对多车道线的检测和行车车道的确认。本文所提出的基于双注意力机制的多车道线检测算法框图如图 3(彩图见期刊电子版)所示。

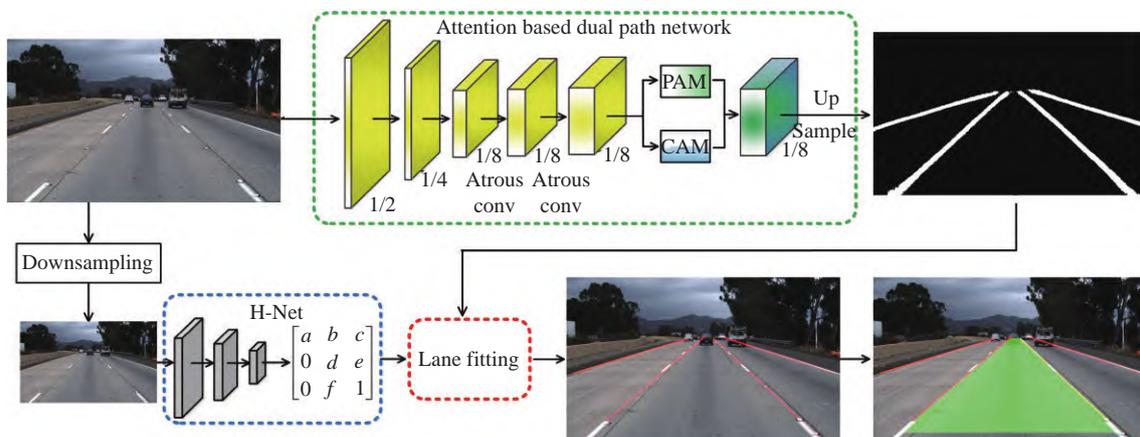


图 3 本文车道线检测算法示意图

Fig. 3 Schematic diagram of proposed lane detection algorithm

3.1 基于双注意力机制的车道线分割

3.1.1 图像特征提取

图像特征提取阶段,为了保证算法的实时性,本文首先借鉴轻量级的 ResNet-18^[17] 网络模型结构,通过对输入图像进行快速降采样来增大网络感受野,同时降低网络结构的复杂度,保证网络的实时性。

在此基础上,为了更好地提取图像特征,避免由于特征图因连续下采样导致的大量细节信息丢失问题,同时为保证网络的感受野大小,本文将 ResNet-18 网络最后的卷积层替换为扩张卷积(Atrous Convolution),以扩大卷积核的感受野并降低降采样率,从而达到控制输出特征图分辨率的目的。针对任意二维特征图,扩张卷积操作如式(1)所示:

$$y[i] = \sum_k x[i+r \times k]w[k] \quad (1)$$

式中: w 表示卷积核; r 表示扩张率; x 和 y 分别表示输入特征图和输出特征图。扩张卷积示意图如图 4 所示。

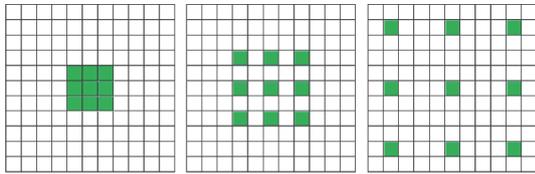


图 4 扩张卷积示意图。(从左至右 r 值分别为 1、2 和 4)

Fig. 4 Diagram of atrous convolution. ($r=1, 2, 4$ from left to right)

3.1.2 空间注意力机制

为了增强网络的推理能力,提高在障碍物遮挡等复杂情况下车道线检测算法的准确性和鲁棒性,本文在设计上述特征提取网络的基础上通过融入双注意力机制(Dual Attention Mechanism)来优化特征提取过程,从而更好地捕获图像的全局上下文语义信息,并准确推测车道线的具体位置。

本文所采用的双注意力机制由空间注意力机制(Position Attention Module, PAM)和通道注意力机制(Channel Attention Module, CAM)两部分组成。空间注意力机制可以看作是一种自适应的空间区域选择机制。在空间注意力机制中,主要依据特征图中任意两个像素之间的语义相关性来捕获空间维度的全局上下文信息。如图 5(彩图见期刊电子版)所示,在上述特征提取过程得到的

特征图 $A \in R^{C \times H \times W}$ 的基础上,本文首先进行卷积操作分别得到新的特征图序列 B 和 C , 然后对上述结果进行变形操作,将特征图变形为 $R^{C \times N}$ 大小,其中 $N = H \times W$; 接着,对其进行转置运算后再对两者进行矩阵乘法运算,继而通过添加 softmax 层得到空间注意力图,并表示为 $S \in R^{N \times N}$, 其原理如式(2)所示:

$$S_{ji} = \frac{\exp(B_i \cdot C_j)}{\sum_{i=1}^N \exp(B_i \cdot C_j)} \quad (2)$$

其中, S_{ji} 可以反应出特征图中任意两个位置 i 和 j 之间的相关性。同样,对特征图 A 进行卷积操作得到 $D \in R^{C \times H \times W}$ 并变形为 $R^{C \times N}$, 然后将其与经过转置运算后的 S 执行矩阵乘法操作,并将结果变形为 $R^{C \times H \times W}$, 最后,将其与参数 α 执行乘法操作并和 A 执行加法操作,得到最终的结果 $E \in R^{C \times H \times W}$ 。如式(3)所示:

$$E_j = \alpha \sum_{i=1}^N (S_{ji} D_i) + A_j \quad (3)$$

其中, α 设置初始值为 0 并在网络训练过程中不断更新。由公式(3)可知,通过引入空间注意力机制,特征图中每个空间位置的特征被赋予了不同的权重。由此,可以得到空间维度的全局上下文信息并对提取到的图像特征进行优化。

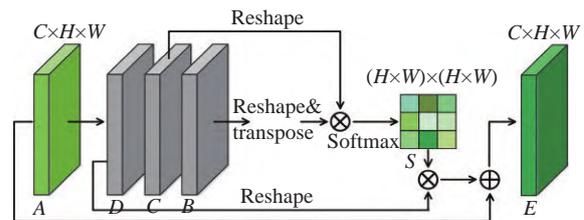


图 5 空间注意力机制示意图

Fig. 5 Schematic diagram of the position attention module

3.1.3 通道注意力机制

针对如图 6 所示的通道注意力机制,首先对特征图 $A \in R^{C \times H \times W}$ 进行变形操作得到 $A \in R^{C \times N}$, 然后,对 A 和其转置执行矩阵乘法操作,接着对上述结果通过添加 softmax 层得到通道注意力特征图 $X \in R^{C \times C}$, 其原理如公式(4)所示:

$$x_{ji} = \frac{\exp(A_i \cdot A_j)}{\sum_{i=1}^C \exp(A_i \cdot A_j)} \quad (4)$$

其中, x_{ji} 可以反应出任意两个特征通道 i 和 j 之间的相关性。在此基础上, 对 X 执行转置运算并将其结果与 A 执行矩阵乘法运算, 继而通过 reshape 操作变形为 $R^{C \times H \times W}$ 。最后, 将其与参数 β 执行乘法操作并和 A 执行加法操作, 并得到最终的结果 $E \in R^{C \times H \times W}$ 。其公式如(5)所示:

$$E_j = \beta \sum_{i=1}^C (x_{ji} A_i) + A_j \quad (5)$$

与空间注意力类似, β 设置初始值为 0 并在网络训练过程中不断更新。

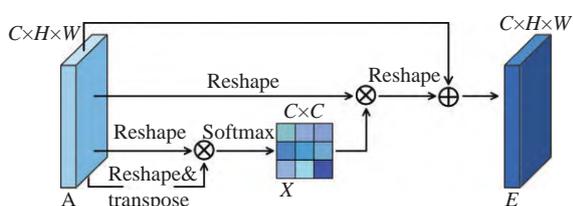


图6 通道注意力机制示意图

Fig. 6 Schematic diagram of the channel attention module

通过引入通道注意力机制, 特征图中每个特征通道被赋予了不同的权重。因此, 可以捕获不同特征通道之间的语义相关性并进一步增强特征的分辨力。

3.2 基于 HNet 的车道线拟合

通过使用上文所述的车道线分割网络进行处理, 输入图像被分割为分别对应着车道线和道路背景的两种语义类别。但是, 车道线检测算法通常要求最终输出车道线的数学参数模型, 即以输入图像为坐标轴, 给出车道线像素点的 y 轴坐标值及对应的 x 轴坐标值。由此, 本节主要在上述车道线分割网络输出的基础上对其进行后处理, 通过对车道线进行曲线拟合, 确定其数学参数模型, 最终实现对车道线的检测。

在进行曲线拟合之前, 由于成像过程中普遍存在的透视效应, 导致原本互相平行的车道线在图像中通常呈现出不同的斜率, 也就是说, 图像中的各车道线之间往往是不平行的, 除此之外, 图像中的车道线还会出现复杂弯曲等现象, 上述问题均不利于车道线的拟合。为了提高曲线拟合的效率和质量, 传统的车道线检测算法常规的做法是先将输入图像映射到鸟瞰视图 (Bird's Eye View, BEV), 使各车道线之间互相平行, 然后再对车道线进行曲线拟合, 对车道线完成拟合之后再经过

逆变换映射回到原图像空间。传统算法通常使用一个固定的预先定义好的变换矩阵对图像进行映射, 但这种方式存在的不足是变换矩阵会受到上坡、下坡等地平面变动的的影响。

针对上述问题, 本文算法后处理步骤借鉴文献 [13] 的思路以实现车道线的拟合并完成检测。不同于传统的依赖预先定义的透视变换矩阵方法, 为了保证在存在上坡及下坡等道路地平面变动的情况下车道线检测算法的鲁棒性, 本文采用基于深度学习的方法得到透视变换矩阵。算法实现方面, 通过设计并训练 HNet 神经网络结构用于生成透视变换矩阵系数。其中, HNet 深度神经网络结构由连续的卷积核为 3×3 的卷积层、BN 层、ReLU 层以及最大池化层构成。如公式 (6) 所示, 通过 HNet 网络结构可以得到拥有 6 个自由度的透视变换矩阵。

$$H = \begin{bmatrix} a & b & c \\ 0 & d & e \\ 0 & f & 1 \end{bmatrix}, \quad (6)$$

本文算法使用由 HNet 输出得到的透视变换矩阵进行透视变换, 并对变换后的车道线像素在变换后的鸟瞰视图进行拟合, 再将拟合结果进行逆投影, 最终得到原始图像空间中的车道线拟合结果, 即车道线的数学参数模型, 从而完成对车道线的检测。其中, 曲线拟合采用最小二乘拟合的思路, 拟合得到三阶多项式。

本文采用 Adam 优化器对 HNet 网络结构进行训练, 批量大小值设置为 10, 学习率设置为 5×10^{-3} 。用于对 HNet 进行网络参数训练的损失函数定义为对车道线进行拟合后逆变换回到原图像空间的车道线点的横坐标值和真实值之间的差方, 如公式 (7) 所示:

$$Loss = \frac{1}{N} \sum_{i=1, N} (x_i^* - x_i)^2 \quad (7)$$

3.3 行车车道确认

不同于传统算法通常预定义了两条待检测车道线的形式, 本文算法将车道线检测任务视作图像语义分割问题, 因此可以针对多条车道线同时进行检测。在此基础上, 为了使车辆能够更加安全高效的行驶, 并为超车等车辆变道功能提供依据, 本文算法提出定义位于图像中线两侧的左右两条车道线分别为车辆当前行驶车道的左右边

界。本文算法将上述两条车道线所包围的区域标记为车辆当前行驶的车道, 以实现对行车车道的确认。

4 实验结果分析

针对本文所提出的基于双注意力机制的车道线检测算法, 本节对其进行定性实验以及定量实验以验证所提出算法的有效性。其中, 本文实验采用 Tusimple 和 CULane 车道线检测数据集, 实验所使用的硬件平台为 Ubuntu 18.04 OS, NVIDIA GTX 2080Ti GPU。算法实现方面, 基于 Pytorch 深度学习框架进行神经网络模型的设计。

4.1 数据集简介

4.1.1 Tusimple 数据集

Tusimple 数据集由图森未来公司开发, 是目前较为常用的用于验证并评价车道线检测算法性能的专用数据集。Tusimple 数据集提供了总计 3626 组标注有车道线边界的训练图像和 2782 组未标注车道线边界的测试图像, 所有图像均采集自较好或者稍好的天气情况, 采集了白天条件下不同时刻的拥有多条车道线的高速公路图像。其中, 用于训练的图像的标注文件为 json 格式, 其提供了许多离散的 y 轴坐标对应的车道线的 x 轴坐标值。

4.1.2 CULane 数据集

CULane 数据集是车道线检测领域的大规模极具挑战性的数据集。该数据集提供了总计 133235 组图像, 其中训练集、验证集和测试集分别包含 88880、9675 和 34680 组图像。所有图像采集自北京市复杂的交通场景下, 场景可分为以下 9 种: normal、crowd、curve、dazzle night、night、no line、shadow、crossroad 和 arrow。

4.2 定性分析

基于所提出的车道线检测算法, 本文首先在 Tusimple 数据集和 CULane 数据集上对其进行了定性实验验证。本文算法在上述两个数据集的定性实验结果分别如图 7 和图 8(彩图见期刊电子版)所示, 其中, 第一列为输入图像; 第二列为本文算法输出的车道线检测结果图像; 第三列为车道确认结果; 第四列为数据集训练集提供的车道线 ground-truth 图像, 即标注有车道线的图像。

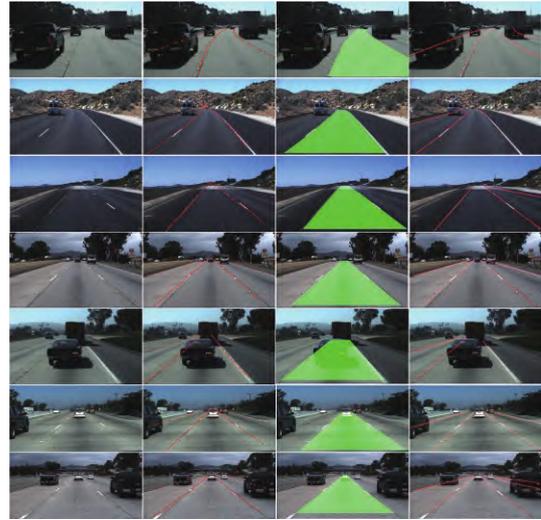


图 7 本文算法 Tusimple 数据集车道线检测结果

Fig. 7 Lane detection results of proposed algorithm on Tusimple

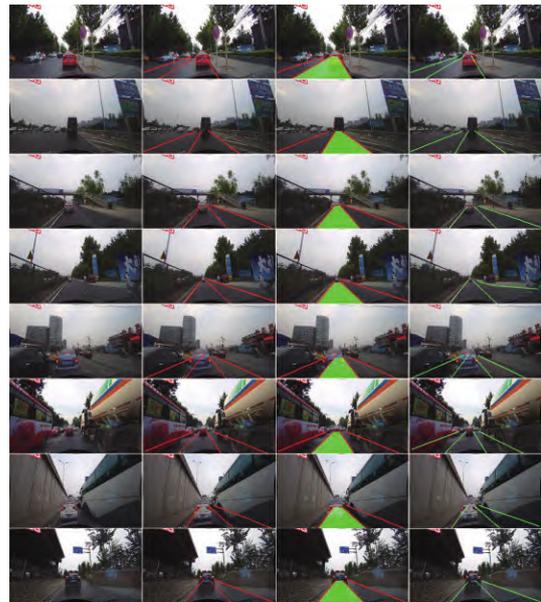


图 8 本文算法 CULane 数据集车道线检测结果

Fig. 8 Lane detection results of our algorithm on CULane

上述定性实验分别选取了 Tusimple 数据集和 CULane 数据集中部分存在车辆等障碍物遮挡、光照变化、车道线信息缺失等极端条件下的实验样本。由上述实验结果可以看出, 本文所提出的基于双注意力机制的车道线检测算法可以在包括障碍物遮挡等不同的道路场景及车道线形态下实现对车道线的有效检测, 算法具有良好的鲁棒性。

4.3 定量分析

针对 Tusimple 数据集, 按照其要求, 本文使

用准确率(accuracy, acc)、错检率(False Positive, FP)以及漏检率(False Negative, FN)作为标准评价车道线检测算法的性能,上述指标定义如下:

$$acc = \sum_{im} \frac{C_{im}}{S_{im}}, \quad (8)$$

$$FP = \frac{F_{pre}}{N_{pre}}, \quad (9)$$

$$FN = \frac{M_{pre}}{N_{gt}}, \quad (10)$$

其中, C_{im} 和 S_{im} 分别表示准确检测到的及总的车道线像素的数量。 F_{pre} , N_{pre} , M_{pre} 和 N_{gt} 分别表示错误检测的,检测到的,没有检测到的以及总的车道线的数量。此外,本文采用指标FPS(Frames Per Second)衡量算法的实时性。

利用以上4种评价标准,使用本文所提出的算法和目前其它具有代表性且拥有出色车道线检测性能的车道线检测算法在Tusimple数据集上进行定量实验对比,结果如表1所示。由表1可知,本文算法的车道线检测准确率达到96.63%,此外,算法以134 frame/s的实时性表现使其相比较其它车道线检测算法的性能有显著优势,目前达到了领先水平。

表1 本文算法在Tusimple数据集定量实验结果

Tab. 1 Quantitative experiment results of proposed algorithm on Tusimple

Method	acc(%)	FP(%)	FN(%)	FPS
SCNN ^[18]	96.53	6.17	1.80	7.5
LaneNet ^[13]	96.38	7.80	2.44	52.6
PolylaneNet ^[19]	93.36	9.42	9.33	115
FastDraw ^[20]	95.20	7.60	4.50	90.3
R-50-E2E ^[21]	96.04	3.11	4.09	-
Ours	96.63	6.02	2.03	134

针对CULane数据集,其规定当预测的车道线和ground-truth的IoU值(Intersection-over-Union)大于0.5时,其结果即可表示为TP(True Positive)。该数据集采用F1-measure值作为评价指标衡量车道线检测算法的性能,其定义如下:

$$F1 - measure = \frac{PRE \times REC}{(1 - \alpha) \times PRE + \alpha \times REC}, \quad (11)$$

where $\alpha = 0.5$,

其中, $PRE = \frac{TP}{TP + FP}$ 表示精确率(Precision), $REC = \frac{TP}{TP + FN}$ 表示召回率(Recall)。

基于上述评价标准,本文车道线检测算法在CULane数据集上各种道路类型的定量实验对比结果如表2所示。由表2可知,本文算法的车道线检测性能同样达到了目前领先的水平。

表2 CULane数据集定量实验结果

Tab. 2 Quantitative experiment results of proposed algorithm on CULane

Method	Normal	Crowd	Dazzle	Shadow	Noline
SCNN ^[18]	90.60	69.70	58.50	66.90	43.40
FastDraw ^[20]	85.90	63.60	57.00	69.90	40.60
UFSD-18 ^[1]	87.70	66.00	58.40	62.80	40.20
UFSD-34 ^[1]	90.70	70.20	59.50	69.30	44.40
LaneATT ^[22]	91.17	72.71	65.82	68.03	49.13
Ours	91.21	76.33	69.51	73.25	50.16
Method	Arrow	Curve	Cross	Night	Total
SCNN ^[18]	84.10	64.40	1990	66.10	71.60
FastDraw ^[20]	79.40	65.20	7013	57.80	-
UFSD-18 ^[1]	81.00	57.90	1743	62.10	68.40
UFSD-34 ^[1]	85.70	69.50	2037	66.70	72.30
LaneATT ^[22]	87.82	63.75	1020	68.58	75.13
Ours	88.72	71.25	1265	70.73	77.32

5 结论

本文根据自动驾驶技术中车道线检测任务的实际应用要求,针对现有车道线检测算法的不足,提出了一种基于双注意力机制的多车道线检测算法。本文研究并设计了基于双注意力机制的车道线分割网络和车道线拟合网络,实现了对多车道线的检测和行车车道的确认。实验结果表明,本文所提出的多车道线检测算法可以在车辆等障碍物遮挡、光照变换、车道线信息缺失等复杂道路场景下实现车道线检测,在Tusimple数据集和CULane数据集的车道线检测精度分别达到了96.63%和77.32%,相比较现有车道线检测算法有了显著提升;此外,本文算法的运行速度为134 frames/s,满足实时性要求。综上所述,本文

算法基本满足了自动驾驶车道线检测的实际应用部署需求。

参考文献:

- [1] 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*, Springer, 2020: 276-291.
- [2] 陈晓冬, 艾大航, 张佳琛, 等. Gabor滤波融合卷积神经网络的路面裂缝检测方法[J]. *中国光学*, 2020, 13(6): 1293-1301.
CHEN X D, AI D H, ZHANG J CH, *et al.*. Gabor filter fusion network for pavement crack detection[J]. *Chinese Optics*, 2020, 13(6): 1293-1301. (in Chinese)
- [3] 任凤雷, 何昕, 魏仲慧, 等. 基于DeepLabV3+与超像素优化的语义分割[J]. *光学精密工程*, 2019, 27(12): 2722-2729.
REN F L, HE X, WEI ZH H, *et al.*. Semantic segmentation based on DeepLabV3+ and superpixel optimization[J]. *Optics and Precision Engineering*, 2019, 27(12): 2722-2729. (in Chinese)
- [4] YU ZH P, REN X ZH, HUANG Y Y, *et al.*. Detecting lane and road markings at a distance with perspective transformer layers[C]. *Proceedings of the 23rd International Conference on Intelligent Transportation Systems*, IEEE, 2020: 1-6.
- [5] CHIU K Y, LIN S F. Lane detection using color-based segmentation[C]. *Proceedings of the IEEE Intelligent Vehicles Symposium*, IEEE, 2005: 706-711.
- [6] HUR J, KANG S N, SEO S W. Multi-lane detection in urban driving environments using conditional random fields[C]. *Proceedings of 2013 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2013: 1297-1302.
- [7] JUNG H, MIN J, KIM J. An efficient lane detection algorithm for lane departure detection[C]. *Proceedings of 2013 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2013: 976-981.
- [8] BORKAR A, HAYES M, SMITH M T. A novel lane detection system with efficient ground truth generation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(1): 365-374.
- [9] VAN GANSBEKE W, DE BRABANDERE B, NEVEN D, *et al.*. End-to-end lane detection through differentiable least-squares fitting[C]. *Proceedings of 2019 IEEE/CVF International Conference on Computer Vision Workshop*, IEEE, 2019: 905-913.
- [10] LIU T, CHEN ZH W, YANG Y, *et al.*. Lane detection in low-light conditions using an efficient data enhancement: light conditions style transfer[C]. *Proceedings of 2020 IEEE Intelligent Vehicles Symposium*, IEEE, 2020: 1394-1399.
- [11] CHANG D, CHIRAKKAL V, GOSWAMI S, *et al.*. Multi-lane detection using instance segmentation and attentive voting[C]. *Proceedings of the 19th International Conference on Control, Automation and Systems*, IEEE, 2020: 1538-1542.
- [12] KIM J, LEE M. Robust lane detection based on convolutional neural network and random sample consensus[C]. *Proceedings of the 21st International Conference on Neural Information Processing*, Springer, 2014: 454-461.
- [13] NEVEN D, DE BRABANDERE B, GEORGIOULIS S, *et al.*. Towards end-to-end lane detection: an instance segmentation approach[C]. *Proceedings of 2018 IEEE intelligent vehicles symposium (IV)*, IEEE, 2018: 286-291.
- [14] LEE H, SOHN K, MIN D. Unsupervised low-light image enhancement using bright channel prior[J]. *IEEE Signal Processing Letters*, 2020, 27: 251-255.
- [15] YOO S, LEE H S, MYEONG H, *et al.*. End-to-end lane marker detection via row-wise classification[C]. *Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, IEEE, 2020: 4335-4343.
- [16] FU J, LIU J, TIAN H J, *et al.*. Dual attention network for scene segmentation[C]. *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2019: 3141-3149.
- [17] HE K M, ZHANG X Y, REN SH Q, *et al.*. Deep residual learning for image recognition[C]. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2016: 770-778.
- [18] 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 and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence*, AAAI Press, 2018: 7276-7283.

- [19] CHEN ZH P, LIU Q F, LIAN CH F. PointLaneNet: efficient end-to-end CNNs for accurate real-time lane detection[C]. *Proceedings of 2019 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2019: 2563-2568.
- [20] PHILION J. FastDraw: addressing the long tail of lane detection by adapting a sequential prediction network[C]. *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, 2019: 11574-11583.
- [21] YOO S, LEE H S, MYEONG H, *et al.*. End-to-end lane marker detection via row-wise classification[C]. *Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, IEEE, 2020: 4335-4343.
- [22] TABELINI L, BERRIEL R, PAIXÃO T M, *et al.*. Keep your eyes on the lane: Real-time attention-guided lane detection[C]. *Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, 2021: 294-302.
- [23] 陈晓冬, 盛婧, 杨晋, 等. 多参数Gabor预处理融合多尺度局部水平集的超声图像分割[J]. *中国光学*, 2020, 13(5): 1075-1084.
CHEN X D, SHENG J, YANG J, *et al.*. Ultrasound image segmentation based on a multi-parameter Gabor filter and multiscale local level set method[J]. *Chinese Optics*, 2020, 13(5): 1075-1084. (in Chinese)
- [24] 周文舟, 范晨, 胡小平, 等. 多尺度奇异值分解的偏振图像融合去雾算法与实验[J]. *中国光学*, 2021, 14(2): 298-306.
ZHOU W ZH, FAN CH, HU X P, *et al.*. Multi-scale singular value decomposition polarization image fusion defogging algorithm and experiment[J]. *Chinese Optics*, 2021, 14(2): 298-306. (in Chinese)

作者简介:



任凤雷(1991—),男,河北沧州人,工学博士,讲师,2015年于吉林大学获得学士学位,2020年于中国科学院长春光学精密机械与物理研究所获得博士学位,主要从事数字图像处理,自动驾驶,视觉环境感知方面的研究。
E-mail: renfenglei15@mails.ucas.edu.cn;
renfl@email.tjut.edu.cn



周海波(1973—),男,黑龙江肇东人,博士,教授,博士生导师,1998年、2005年于佳木斯大学分别获得学士、硕士学位,2009年于吉林大学获得博士学位,主要从事计算机视觉、人工智能、智能机器人技术等方面的研究。E-mail: haibo_zhou@163.com