

DOI: 10.13382/j.jemi.B2206068

多分支融合注意力机制的车道线检测模型^{*}

蒯 晓 丁 飞 张登银

(南京邮电大学物联网学院 南京 210003)

摘 要:为了解决目前车道线检测过程中特征融合不充分、检测精确度低和鲁棒性差的问题,本文提出一种融合多分支结构和注意力机制的车道线检测模型 (fusion of multi-branch structure and attention mechanism network,FMANet),图像编码部分采用多分支结构和注意力机制,并选择 swish 作为激活函数,图像解码部分采用跳跃连接结构,实现跨层特征融合。本文利用 TuSimple 公开数据集对 FMANet 模型进行评估与验证,实验结果表明,本文所提的 FMANet 模型的 mAP 指标接近 97.25%,车道线检测精确度达到 98.15%,此外,通过 CULane 数据集验证 FMANet 模型在不同场景下的检测具有更好的鲁棒性。

关键词: 车道线检测;特征融合;多分支结构;注意力机制;激活函数;跳跃连接结构

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.4

Lane detection model of multi-branch fusion attention mechanism

Kuai Xiao Ding Fei Zhang Dengyin

(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: In order to solve the problems of inadequate feature fusion, low detection accuracy and poor robustness in current lane detection, this paper proposes a lane detection model called fusion of multi-branch structure and attention mechanism network (FMANet). In the image coding part, fusion of multi-branch structure and attention mechanism is adopted. swish is selected as the activation function, and the image decoding part adopts the jump connection structure to achieve cross-layer feature fusion. In this paper, TuSimple public dataset was used to evaluate and verify the FMANet model. The experimental results show that the mAP index of the FMANet model proposed in this paper is close to 97.25%, and the lane detection accuracy reaches 98.15%. In addition, CULane dataset verifies that the FMANet model has better robustness in different scenarios.

Keywords: lane line detection; fusion of features; multi-branch structure; attention mechanism; activation function; skip connection structure

0 引 言

据统计,2021 年全国机动车交通事故发生数量为 211 074 起,其中汽车交通事故数量为 156 901 起,由车道线偏离导致的交通事故数量大约为 50%^[1]。车道线检测作为智能网联交通系统 (intelligent connected transportation system, ICTS) 的重要组成部分,其研究已经成为路网交通检测方向的研究热点之一^[2]。基于高级驾驶辅助系统 (advanced driver assistance system, ADAS) 进

行车道线检测,达到行车安全,避免事故发生的目的,可以支撑其驾驶决策与控制^[3]。因此,研究智能网联交通场景下车道线检测模型并实时、精确地执行车道线检测任务,有利于车辆控制优化与协调,从而提升路网整体运行效率。

传统车道线检测方法可分为基于特征的方法,基于几何模型的方法以及基于深度学习模型的方法^[4]。基于特征的车道线检测方法,主要是利用车道线与路面及其周边之间的纹理、灰度值、梯度变化以及边缘等特征差异,通过阈值分割将车道线特征信息从图片中分离出来。

付利军等^[5]首先提取图像的边缘信息,然后选择特定的梯度方向细化感兴趣区域以抑制非车道线边缘等杂乱背景的影响,最后利用方向区间与阈值对 Hough 变换改进来检测车道线。刘源等^[6]基于车道线边缘的梯度分布和灰度分布提取边缘特征点提出一种基于边缘特征点聚类的车道线检测方法,根据车道线特征依次进行特征点聚类 and 区域聚类,再挑选出最优点进行拟合。赵岩等^[7]提出一种基于轮廓筛选的车道线检测方法,提取车道线特征点进而拟合车道线。Li J 等^[8]采用基于梯度和背景差异的多通道阈值融合方法,结合车道线的色相饱和度 (hue saturation value, HSV) 特征进行车道线检测。基于特征的车道线检测方法对噪声比较敏感,且易受到车道线遮挡及破损的影响,鲁棒性较差。

基于模型的方法主要是通过匹配车道线的特征点和车道线的几何模型来提取车道线。Cai 等^[9]建立一种高斯统计颜色模型在感兴趣区域提取车道线颜色,利用改进的霍夫变换检测车道线。姜立标等^[10]设计了一种结合改进 Hough 变换和双点去除 R-最小二乘法检测车道线。吕侃徽等^[11]使用 Hough 变换和密度空间聚类提出一种稳健的车道线检测算法,将车道线分解成小线段,再分别进行聚类 and 检测。Jung 等^[12]提出了一种基于实例分割的车道检测方法,利用图像坐标直接优化像素空间的嵌入,实现轻量级的车道检测模型。宋宝玉等^[13]设计了一种基于树莓派嵌入式平台的车道线检测算法,完整地提取二值化后的车道线信息,同时以图像融合的方式有效过滤干扰信息,能够适用于多道路场景。基于模型的车道线检测方法是建立在特定几何模型基础上,通过分析道路图像中的目标信息来确定相应的模型参数,不仅实时性好且抗噪声强,对于车道线被遮挡、路面存在干扰的情况具有较好的鲁棒性,能够有效解决基于特征的车道线检测方法所存在的问题,但是单一路模型难以适应现实中复杂的道路线形与各种路况。

基于深度学习的车道线检测的基本思想主要是通过搭建一个深层神经网络模型来实现车道线检测,然后使用大量数据对网络进行训练,让其自动提取车道线特征进而实现车道线的识别。Ko 等^[14]设计了一种提出基于关键点车道线检测的 PINet 模型,车道线匹配性能较优。Tripathi 等^[15]使用带有过拟合特征的滑动窗口进行车道线检测。Hou 等^[16]提出一种图像局部匹配算法 (sum of absolute differences, SAD),通过使用语义分割和知识蒸馏能够增强卷积神经网络的特征表达能力。Tung 等^[17]将不同样本特征的相似性得分作为蒸馏目标。Su 等^[18]通过 SGNNet 模型充分利用车道线相关的结构信息,可以准确提取出车道线并对车道线进行分类和定位。张森等^[19]针对复杂道路环境设计了一种定向距离变换耦合多粒子滤波器的车道线检测算法。基于深度学习的车

道线检测通过深层神经网络模型进行车道线检测,在满足基于模型的方法的要求上,能够适应更多的复杂路况。

然而,在现有的基于深度学习的车道线检测方法中,仅仅依靠单分支的神经网络结构难以实现高精度的前方车道线检测要求,图像数据信息在不断的下采样学习中容易丢失高分辨率的特征信息,从而导致特征融合不充分以及最终的检测结果精度不足。此外,在深度学习中,神经网络的学习会因为网络深度的增加而收敛缓慢,甚至出现梯度消失的问题。

为此,本文提出一种融合多分支结构和注意力机制的车道线检测模型 (fusion of multi-branch structure and attention mechanism network, FMANet)。首先,基于像素值进行图像分割,对原始图像进行感兴趣区域提取。其次,为了解决在车道线检测过程中由于高分辨率特征信息丢失而导致特征融合不充分、检测精确度低的问题,本文将使用多分支结构和注意力机制来增强特征提取能力,在传递过程中保留更多的细节信息。最后,针对由于网络深度增加而导致神经网络的学习收敛缓慢,甚至出现梯度消失的问题,本文将使用 swish 函数和跳跃连接结构来加速网络收敛,通过特征融合提高模型的整体性能。

1 FMANet 模型构建

在车道线检测过程中,首先使用车载摄像头采集前方道路视频流,其次将视频流转换为连续帧图像,然后动态提取其感兴趣区域,最后交付至 FMANet 模型进行处理,实现了高效且精确的车道线检测。该模型进行车道线检测的具体步骤主要包括:

- 1) 选取公开基准数据集,对其中的车道线图像基于像素值进行图像分割,图像分割的过程如图 1 所示,根据各图像块的平均像素值提取包含车道线的感兴趣区域,剔除与车道线检测无关的干扰因素,例如天空、道路两侧树木等等,可以极大程度地降低模型的计算量,提高车道线检测精度。

- 2) 将图像缩小至 48×48 ,将处理后拥有统一形式的图像作为整个训练网络的输入;

- 3) 将图像输入到 FMANet 模型的图像编码部分,使用卷积操作和 swish 函数进行图像特征提取,并采用多分支结构和注意力机制,在传递过程中提取更多的特征信息。此时图像的尺寸逐渐变小;

- 4) 将提取后的特征送至 FMANet 模型的图像解码部分进行解码,在车道线检测方法的图像解码部分,使用跳跃连接结构并通过逆卷积操作还原图像特征,将图像逐渐恢复到原始尺寸;

- 5) 通过 softmax 函数输出最终的语义分割图;

6) 调用训练所得到的车道线检测模型对 TuSimple 数据集中的验证集的数据图像进行检测,并输出最终车道线检测结果。

本文提出的 FMANet 模型的网络架构如图 2 所示,

该方法在满足车道线检测实时性的要求下,引入多分支结构、注意力机制、swish 激活函数和跳跃连接结构,形成一个高精度的车道线检测网络。




图 1 基于图像分割的感兴趣区域图像

Fig. 1 Region of interest image based on image segmentation




图 2 FMANet 模型的网络架构

Fig. 2 Network architecture of FMANet model

2 模型方法

2.1 多分支结构

在传统车道线检测方法的网络结构中,人们通常只关注上下文特征之间的关联,而很少注意在前向传播过程中高低分辨率特征之间的关联。在许多应用场景之下,仅仅依靠单分支结构的神经网络并不能够为用户提

供高精度的车道线检测服务,图 3(a) 展示了常用的单分支网络基本结构,在这种神经网络结构中,图像数据信息容易在不断进行的下采样学习过程中丢失高分辨率的特征信息,从而导致特征融合不充分、检测精度不足。图 3(b) 展示了常用的多分支网络基本结构,在这种结构中,在较深的分支输入低分辨率图片,目的是为了在保证较少计算开销的前提下有效地提取全局上下文特征;较浅的网络分支输入高分辨率图像,目的是提取空间细节

信息。多个分支的计算结果融合,形成最终的语义分割结果。

然而,上述常用的多分支网络基本结构也存在一定的缺点,由于部分模型参数属于无效参数,并不参与后续的计算,因而存在一定的冗余,会造成计算资源的浪费。本文提出的多分支网络基本架构如图 3 所示,图像数据信息在前向传递过程中,通过下采样操作不断学习低分辨率的特征信息,同时也保留了高分辨率的特征信息。此外,通过裁剪掉冗余的网络结构,可以确保利用最少的计算资源消耗学习更加丰富的特征。




图 3 目标检测通用网络结构

Fig. 3 General network structure of target detection

为进一步提升网络的特征提取能力,确保特征信息能够准确传递,并且不丢失其细节信息,本文在图像编码部分的传递路径上引入了图 4 的结构,同时通过多次卷积操作以达到充分提取图像的特征信息,从而使所有输入的特征由多分支结构进行提取与传递,能够提高特征的重用性。

2.2 注意力机制模块

为了增强模型在通道、空间维度上的特征提取能力,本文的 FMANet 模型使用 CBAM (convolutional block attention module) 模块,通过对传递特征的筛选,并且传递更多的细节信息,有利于特征充分融合、训练损失的降低以及准确的定位。




图 4 改进的多分支结构

Fig. 4 Improved multi-branch structure

CBAM^[20] 是一种可以无缝集成到卷积神经网络架构的轻量级通用模块,结合通道和空间两个维度的注意力机制,在两个维度上利用通道、空间之间的关系差异,学习不同权重网络的特征图,优于仅在通道维度上提取权重的传统网络 SENet^[21]。CBAM 模块结构如图 5 所示,原始输入特征图 F ,根据空间维度和通道维度计算注意力权重,然后将注意力权重作用在原始特征图上,得到结果特征图。这不但可以减少参数,节约计算,而且整个模块可以加入到现有的神经网络中。




图 5 CBAM 模块结构

Fig. 5 CBAM module structure

本文提出融合注意力机制的特征提取网络结构如图 6 所示。通过通道注意力模块和空间注意力模块分别对特征图进行处理,再将两者所输出的特征做相加操作并送入 3×3 卷积层,通过 Sigmoid 函数来处理特征图并进行特征加权操作,最后将加权后的结果输入到最大池化层进行信息筛选。




图 6 融合注意力机制的特征提取网络

Fig. 6 Feature extraction network incorporating attention mechanism

2.3 swish 激活函数

在深度学习中,神经网络通常使用 ReLU^[22] 激活函数和归一化层以加快网络收敛速度。其中 ReLU 激活函数的公式为:

$$ReLU(x) = \begin{cases} \max(0, x) & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (1)$$

然而,传统的 ReLU 激活函数,当输入为负值时,会因为对负值取 0 的特性,从而导致丢失部分的特征信息,存在精度不够的问题,所以本文所提出的 FMANet 模型在图像编码过程中选择使用 swish 作为激活函数,来减少由于网络层数增加而造成网络梯度消失的影响。

swish 的计算方法如下:

$$swish(x) = x \cdot Sigmoid(\beta \cdot x)$$

$$Sigmoid = \frac{1}{e^{-x} + 1} \quad (2)$$

其中, β 是个可训练的参数或者为可调节常量,通过此参数可以动态的调节 swish 函数,当 $\beta = 1$ 时,则 $swish(x) = x \cdot Sigmoid(x)$,此时 swish 函数相当于 SiLU (sigmoid-weight linear unit, SiLU) 激活函数;当 $\beta = 0$ 时,则 $swish(x) = x/2$,swish 自适应成为线性函数;当 $\beta \rightarrow \infty$ 时,swish 函数相当于 ReLU 激活函数。swish 具有无上界、平滑、非单调的特性。与 ReLU 激活函数相比,swish 可以更好的提升网络的准确性,同时有利于网络收敛。

2.4 跳跃连接结构

在基于深度学习的车道线检测方法中,网络深度达到一定程度后,网络学习会因为网络层数的增加而导致收敛缓慢。如图 7 所示,本文在 FMANet 模型的图像解码部分,使用跳跃连接结构进行网络学习,同时在此基础上,结合使用逆卷积操作。首先使用逆卷积操作来还原图像分类后的特征,其次对数据进行归一化操作,最后使用跳跃连接结构将图像编码过程的特征图与图像解码过程的特征图进行连接,实现跨层特征融合,使得网络在向传播时可以融合上下文信息,并且在损失方向传播时可以进行无损传播,加速网络收敛。




图 7 跳跃连接结构

Fig. 7 Skip connection structure

3 实验分析

3.1 实验配置与评价指标

为了评估本文所提出的 FMANet 模型的有效性,采用无人驾驶场景下的 TuSimple^[23] 数据集和 CULane^[24] 数据集分别进行训练和性能分析。其中 TuSimple 数据集共有 13 910 张道路图片,按照 8:2 的比例划分训练集与验证集,数据集中包含的图像类别有白天不同的时间段、不同的车道数目以及不同的交通状况。此外, CULane 数据集共有 133 235 张图片,其中有 9 种驾驶场景,包括常规、拥堵、夜间、非结构化、阴影、箭头、强化、弯道和路口。

本文的实验操作系统为 Windows 10 操作系统, GPU 使用 VIDIA Geforce RTX 2060 with Max-Q Design, 内存 32 G, CPU 使用 Intel Core i7-10750H, 算法的仿真实验基于 Python 语言, 使用 Pycharm 开发工具和深度学习框架 TensorFlow2.3.1 进行开发, 利用 OpenCV2 划分训练集和验证集。本文在训练过程中设置 Batch Size 为 16, epoch 为 20, 在实验中使用 ImageDataGenerator 进行数据增强, 设置 channel_shift_range 参数为 0.2。最后, 本文实验选用 Adam 优化器, 损失函数采用均方损失函数 MSE (mean squared error) Loss。

本文采用准确率、精确度、召回率、 $F1 - score$ 、损失率等技术指标进行性能分析, 以此来衡量 FMANet 模型的检测性能。在车道线检测中, TP 表示模型检测正确的车道线数量, FP 表示模型检测错误的数量, FN 表示漏检的数量, TN 表示没有检测出来的实际不存在的车道线。

通过 TP 、 FP 、 FN 和 TN , 可以计算出精确度 P 和召回率 R , 精确度 P 表示预测样本中实际正样本数占有正样本数的比例, 计算方法如下所示:

$$P = \frac{TP}{TP + FP} \quad (3)$$

召回率 R 表示预测样本中实际正样本数占有所有预测的样本的比例, 其计算公式如下:

$$R = \frac{TP}{TP + FN} \quad (4)$$

考虑到精确度或召回率只反映车道线检测性能的一个方面, 在深度学习中, 可以使用 $F1 - score$ 作为一个整体来评价模型的优劣, 它表示的是精确度 P 和召回率 R 的加权调和平均, $F1 - score$ 的定义如下:

$$F1 - score = \frac{2 \times P \times R}{P + R} \quad (5)$$

准确率 (accuracy) 表示预测样本中预测正确数占有所有样本数的比例, 其计算如式 (6) 所示:

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (6)$$

为了判定预测模型的精确度,本文使用的损失函数是均方差 MSE (mean squared error) 函数,其计算公式为:

$$MSE = \frac{1}{n} \times \sum (accuracy - prediction)^2 \quad (7)$$

均值平均准确度 mAP 是度量检测模型在所有类别上的精度的指标,简单来说,就是对所有类别上的平均准确度 AP 求平均值,其中 AP 表示单个类别的精确度的平均值, AP 计算方法如式(8)所示, mAP 计算方法如式(9)所示:

$$AP = \frac{1}{N} \sum_{i=1}^N P_i \quad (8)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (9)$$

3.2 性能对比与分析

为了验证本文 FMANet 模型的有效性,本文首先与 SegNet^[25] 网络在准确率、损失和精确度这 3 个评价指标进行实验对比。其中,图 8 展示了 FMANet 网络和 SegNet 网络的检测准确率的对比结果,在迭代开始的时候,训练集的准确率有明显的起伏,但是当迭代次数越来越多时,准确率处于稳定上升的趋势。实验分析表明,FMANet 的准确率明显优于 SegNet 网络。




图 8 不同模型的准确率对比

Fig. 8 Accuracy comparison among different models

本文在实验中设置损失函数为 MSE Loss 函数,通过实验分析,FMANet 模型与 SegNet 模型训练迭代的损失对比结果如图 9 所示,可以看出 FMANet 模型的迭代损失明显低于 SegNet 模型。结合图 8 的检测准确率的对比分析,FMANet 模型的准确率提高约 0.3%,且训练迭代的损失减少约 0.4%,因此,本文提出的 FMANet 模型具有更优的性能。

FMANet 模型与 SegNet 模型的精确度对比结果如图 10 所示,实验结果表明,相比 SegNet 模型,FMANet 在




图 9 不同模型的损失对比

Fig. 9 Loss comparison among different models

训练集的精确度提升了 1.54%,在验证集上精确度增长了 1.46%。因此,FMANet 模型的车道线检测精度更高。




图 10 不同模型的精确度对比

Fig. 10 Precision comparison among different models

为了全面验证本文 FMANet 模型的有效性,使用多个主流模型与 FMANet 模型进行实验对比分析,实验结果如表 1 所示,本文所提出的 FMANet 模型在车道线检测的各项性能指标上均明显优于 PINet、SAD、SCNN、VGGNet 和 SegNet 等 5 个主流模型,FMANet 模型的准确率和精确度达到了 96.38% 和 98.12%。PINet 和 SAD 模型由于具有较多的参数导致在车道线检测过程中的表现较差;SCNN 网络由于网络结构较深,并且采用行列卷积的形式,也获得了不错的检测精度;SAD 网络和 SCNN 模型在准确率和精确度上并没有较大的差异。在模型检测速度方面,虽然 FMANet 网络深度的增加会导致模型的计算量上升,但是对原始图像进行了感兴趣区域的提取,减少了许多冗余信息的计算,因此 FMANet 整体模型的检测速度有了进一步的提高,可以更加满足实时性要求,实现了精确度与实时性的双向兼容。

表 1 不同网络的验证集性能对比

Table 1 Performance comparison of validation set among different networks							
网络	准确率/%	精确度/%	召回率/%	$F1-score$ /%	损失/%	mAP /%	检测速度/fps
PINet ^[14]	96.72	92.99	90.62	91.58	3.92	97.67	25
SAD ^[16]	95.30	95.26	89.22	90.47	4.32	96.48	19.8
SCNN ^[26]	95.21	95.48	92.67	93.26	8.46	95.89	23.8
VGGNet ^[27]	81.78	85.08	77.36	85.31	9.75	83.21	17.6
SegNet ^[25]	96.12	96.67	96.63	96.65	0.45	95.34	28.4
FMANet	96.38	98.12	98.07	98.10	0.12	96.76	30.1

3.3 消融实验

为了验证本文模型所使用方法的有效性,对本文提出的 FMANet 模型进行消融实验。在消融实验过程中所涉及模型如下:

- 1) SegNet:一种经典的用于语义分割的编码解码结构神经网络,编码器与 VGGNet 相同;
- 2) SegNet_OMBS:在 SegNet 的基础上使用多分支结构;
- 3) SegNet_NMBS:在 SegNet 的基础上使用裁剪后的多分支结构;
- 4) SegNet_NMBC:在 SegNet_NMBS 的基础上融合 CBAM 模块;
- 5) NMBC_swish:在 SegNet_NMBC 的基础上使用 swish 激活函数;
- 6) FMANet:在 NMBC_swish 的基础上添加跳跃连接结构。

实验结果如表 2 所示,在 SegNet 网络的基础上使用裁剪的多分支结构性能明显优于多分支结构;与 SegNet 相比较,SegNet_NMBS 的精确度、召回率和 $F1-score$ 显著提升 0.58%、0.5% 和 0.53%,表明使用裁剪的多分支结构可以充分学习图像丰富的特征信息,并且融合低分辨率和高分辨率特征信息。

在 SegNet_NMBS 网络的基础上添加 CBAM 模块,相比 SegNet_NMBS 网络,SegNet_NMBC 模型的精确度和 $F1-score$ 分别提高了 0.36% 和 0.35%。

NMBC_swish 网络在 SegNet_NMBC 的基础上使用 swish 函数,NMBC_swish 网络的准确率提高 0.11%,同时在检测精度和 $F1-score$ 指标方面明显提升 0.28% 和 0.35%,弥补使用 ReLU 激活函数导致的丢失特征信息

的问题,有效提高车道线检测精度。

FMANet 网络以 NMBC_swish 网络为前提,添加跳跃连接结构,FMANet 网络在准确率、精确度、召回率和 $F1-score$ 方面都有所提升,其中精确度提高了 0.28%,充分表明通过跳跃连接结构实现跨层特征融合,可以有效提高模型的性能。

表 2 消融实验结果

Table 2 Results of ablation experiment (%)				
网络	准确率	精确度	召回率	$F1-score$
SegNet	96.12	96.67	96.63	96.65
SegNet_OMBS	96.13	96.93	96.98	96.97
SegNet_NMBS	96.15	97.23	97.13	97.18
SegNet_NMBC	96.19	97.59	97.45	97.53
NMBC_swish	96.30	97.87	97.79	97.88
FMANet	96.33	98.15	98.10	98.12

3.4 鲁棒性测试

为了验证本文 FMANet 模型的鲁棒性,实际场景中,车道线检测模型需要处理各种不同的驾驶场景,如拥堵、强光、弯道等,因此,本文使用具有多种驾驶场景的数据集进行验证。

表 3 为各种网络在 CULane 数据集上的实验结果,从结果可以看出,在 8 种车道线场景下,FMANet 网络的检测精度均优于其他网络。在非结构化道路场景下,由于道路没有清晰的车道线和道路边界,同时道路特征较为模糊,受到其他因素影响较大,从而导致 FMANet 网络提取车道线特征更加困难,因此 FMANet 网络对非结构化道路场景下的车道线检测精度有些许降低。总的来说,FMANet 网络可以适应更多的复杂场景,具有较好的鲁棒性。

表 3 不同网络的 CULane 车道线检测精确度对比

Table 3 Precision comparison of CULane detection among different networks (%)									
网络	常规	拥堵	夜间	非结构化	阴影	箭头	强光	弯道	路口
PINet ^[14]	90.31	72.32	67.74	49.82	68.41	83.73	66.35	65.62	74.43
SAD ^[16]	90.12	68.83	65.98	41.65	65.93	84.02	60.27	65.71	65.38
SCNN ^[26]	90.62	69.71	66.09	43.12	66.92	84.14	58.49	64.41	53.18
VGGNet ^[27]	80.30	59.23	56.14	33.72	54.16	68.35	45.62	50.22	48.76
SegNet ^[25]	91.25	72.38	68.42	53.48	69.82	85.67	65.03	66.32	75.92
FMANet	92.63	74.80	69.23	53.37	70.38	87.98	68.72	67.23	76.54

4 结 论

为了解决车道线检测过程中存在的问题,包括分辨率特征信息丢失而导致特征融合不充分、检测精确度低,网络深度增加而导致神经网络的学习收敛缓慢,甚至出现梯度消失,本文提出一种融合多分支结构和注意力机制的车道线检测模型 FMANet。首先,本文在 FMANet 模型中采用多分支网络结构;其次使用 CBAM 模块融入注意力机制;然后,使用 swish 激活函数减少由于网络层数增加所造成网络梯度消失的影响;最后,在图像解码部分使用跳跃连接结构将图像编码过程的特征图与图像解码过程的特征图进行连接。在公开基准数据集上进行实验,验证了本文模型的有效性。与其他网络相比,FMANet 模型具有较高的准确率、精确度、召回率和 $F1 - score$ 。此外,FMANet 模型在 CULane 数据集上进行了测试,验证其鲁棒性。结果表明,FMANet 模型能够在各种场景下稳定的检测出车道,并能降低误检率,能够适应多种驾驶场景。

参考文献

- [1] ALI F, ALI A, IMRAN M, et al. Traffic accident detection and condition analysis based on social networking data[J]. Accident Analysis & Prevention, 2021, 151: 105973.
- [2] HAN Y, WANG B, GUAN T, et al. Research on road environmental sense method of intelligent vehicle based on tracking check[J]. IEEE Transactions on Intelligent Transportation Systems, 2022.
- [3] RUNDO F, ANFUSO I, AMORE M G, et al. Advanced eNose-driven pedestrian tracking pipeline for intelligent car driver assisting system: preliminary results[J]. Sensors, 2022, 22(2): 674.
- [4] 刘宇,韩磊,王庆庆,等.基于视觉的车道线检测算法研究综述[J].汽车实用技术,2021,46(22):24-27.
LIU Y, HAN L, WANG CH Q, et al. Overview of research on vision-based lane line detection algorithms[J]. Automobile Applied Technology, 2021, 46(22): 24-27.
- [5] 付利军,兰方鹏.边缘信息耦合改进的 Hough 变换的车道线实时检测算法[J].电子测量与仪器学报, 2019, 33(8): 166-172.
FU L J, LAN F P. Lane detection algorithm based on edge information coupling improved Hough transforms[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 166-172.
- [6] 刘源,周聪玲,刘永才,等.基于边缘特征点聚类的车道线检测[J].科学技术与工程,2019,19(27): 247-252.
LIU Y, ZHOU C L, LIU Y C, et al. Lane detection based on edge feature points clustering[J]. Science Technology and Engineering, 2019, 19(27): 247-252.
- [7] 赵岩,赵建国.一种移动车辆遮挡下的车道线检测方法[J].科学技术与工程,2021,21(7):2782-2787.
ZHAO Y, ZHAO J G. Lane line detection algorithm under moving vehicle occlusion[J]. Science Technology and Engineering, 2021, 21(7): 2782-2787.
- [8] LI J, SHI X, WANG J, et al. Adaptive road detection method combining lane line and obstacle boundary[J]. IET Image Processing, 2020, 14(10): 2216-2226.
- [9] CAI H, HU Z, HUANG G, et al. Robust road lane detection from shape and color feature fusion for vehicle self-localization[C]. 2017 4th International Conference on Transportation Information and Safety (ICTIS). IEEE, 2017: 1009-1014.
- [10] 姜立标,李静轩.基于改进 Hough 变换与双点去除 R-最小二乘法的车道线检测优化算法[J].科学技术与工程,2020,20(5):2070-2076.
JIANG L B, LI J X. Lane line detection optimization algorithm based on Improved Hough transform and R-least squares with dual removal[J]. Science Technology and Engineering, 2020, 20(5): 2070-2076.
- [11] 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.
- [12] JUNG S, CHOI S, KHAN M A, et al. Towards lightweight lane detection by optimizing spatial embedding[J]. arXiv preprint arXiv:2008.08311, 2020.
- [13] 宋宝玉,王波涛.基于树莓派嵌入式平台的车道线检测算法[J].电子测量技术,2021,44(23):93-98.
SONG B Y, WANG B T. Lane line detection algorithm based on Raspberry Pi embedded platform[J]. Electronic Measurement Technology, 2021, 44(23): 93-98.
- [14] KO Y, LEE Y, AZAM S, et al. Key points estimation and point instance segmentation approach for lane detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(7): 8949-8958.
- [15] TRIPATHI R, VYAS S, TEWARI A. Behavioral cloning for self-driving cars using deep learning[C]. Proceedings of International Conference on Big Data, Machine Learning and their Applications. Springer, Singapore, 2021: 197-209.

- [16] 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, 2019: 1013-1021.
- [17] TUNG F, MORI G. Similarity-preserving knowledge distillation [C]. Proceedings of the IEEE /CVF International Conference on Computer Vision, 2019: 1365-1374.
- [18] SU J, CHEN C, ZHANG K, et al. Structure guided lane detection [J]. arXiv preprint arXiv: 2105.05403, 2021.
- [19] 张森,董赞强,陈源. 基于定向距离变换耦合多粒子滤波器的车道线检测算法[J]. 电子测量与仪器学报, 2020,34(6):93-101.
ZHANG S, DONG Z Q, CHEN Y. Lane line detection based on oriented distance transform coupled multi-particle filter [J]. Journal of Electronic Measurement and Instrumentation, 2020,34 (6) : 93-101.
- [20] YANG Q, MA Y, LI L, et al. Lightweight lane line detection based on learnable cluster segmentation with self-attention mechanism [J]. IET Intelligent Transport Systems, 2023, 17(3) : 522-533.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [22] DAUBECHIES I, DEVORE R, FOUCART S, et al. Nonlinear approximation and (deep) ReLU networks [J]. Constructive Approximation, 2022, 55(1) : 127-172.
- [23] WEN T, YANG D, JIANG K, et al. Bridging the gap of lane detection performance between different datasets: Unified viewpoint transformation [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22 (10) : 6198-6207.
- [24] PAN X, SHI J, LUO P, et al. Spatial as deep: Spatial cnn for traffic scene understanding [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018.
- [25] YAMANAKKANAVAR N, CHOI J Y, LEE B. SM-SegNet: A lightweight squeeze M-SegNet for tissue segmentation in brain MRI scans [J]. Sensors, 2022,

22(14) : 5148.

- [26] JIANG L, MINGHUI X, YU Z. Land segmentation and contour extraction of remote sensing image based on mask R-CNN [J]. Nanjing Xinxing Gongcheng Daxue Xuebao, 2021, 13(1) : 116-123.
- [27] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv:1409.1556, 2014.

作者简介



蒯晓, 2019 年于淮阴师范学院获得学士学位,现就读于南京邮电大学,主要研究方向为车联网、图像处理和深度学习。

E-mail: 1712615324@qq.com

Kuai Xiao received her B. Sc. degree from Huaiyin Normal University in 2019. Now she is a M. Sc. candidate at Nanjing University of Posts and Telecommunications. Her main research interests include internet of vehicles, image processing and deep learning.



丁飞, 2010 年于东南大学获得博士学位,现为南京邮电大学副教授,主要研究方向为智能网联汽车通信与网络技术、边缘计算和协同计算技术。

E-mail: dingfei@njupt.edu.cn

Ding Fei received his Ph. D. degree from Southeast University in 2010. Now he is an associate professor in Nanjing University of Posts and Telecommunications. His main research interests include communication and networking technology of intelligent connected vehicles, edge intelligence, and collaborative computing technology.



张登银 (通信作者), 2004 年于南京邮电大学获得博士学位,现为南京邮电大学研究员,主要研究方向为信号与信息处理、网络技术与信息安全。

E-mail: zhangdy@njupt.edu.cn

Zhang Dengyin (Corresponding author) received his Ph. D. degree from Nanjing University of Posts and Telecommunications in 2004. Now he is a researcher in Nanjing University of Posts and Telecommunications. His main research interests include signal and information processing, network technology and information security.