

# 基于卷积神经网络的车道线实例分割算法

周苏<sup>1</sup>, 吴迪<sup>2\*</sup>, 金杰<sup>1</sup>

<sup>1</sup> 同济大学汽车学院, 上海 201804;

<sup>2</sup> 同济大学中德学院, 上海 201804

**摘要** 车辆行驶环境感知是自动驾驶领域的重点和难点问题, 其中车道线检测是车辆行驶环境感知的基础。针对不同实例车道线难以区分、现有区分算法时间复杂度高、不同行驶场景需人为调整超参数等问题, 提出了一种三支车道线实例分割算法, 并对分割结果进行自适应聚类以拟合不同实例车道线。针对车载摄像头获取的图像数据不均衡特点, 用基于三分视野法的 Tversky Loss 函数对卷积神经网络进行训练。针对车道线大曲率半径的特点, 以高次项权重作为最小二乘法正则项拟合车道线。在 TuSimple 数据集上的测试结果表明, 本算法对实例车道线的识别准确率为 96.23%, 相比 LaneNet, 本算法的时间消耗减少了 23.67%, 且对不同车辆行驶场景都有较好的检测效果。

**关键词** 机器视觉; 卷积神经网络; 车道线检测; 实例分割; 自适应聚类

中图分类号 U495

文献标志码 A

doi: 10.3788/LOP202158.0815007

## Lane Instance Segmentation Algorithm Based on Convolutional Neural Network

Zhou Su<sup>1</sup>, Wu Di<sup>2\*</sup>, Jin Jie<sup>1</sup>

<sup>1</sup> School of Automotive Studies, Tongji University, Shanghai 201804, China;

<sup>2</sup> Chinesisch-Deutsches Hochschulkolleg, Tongji University, Shanghai 201804, China

**Abstract** Vehicle driving environment perception is a key and difficult problem of automatic driving field, among which lane detection is the foundation of vehicle driving environment perception. In view of the difficulty in distinguishing different lane instances, the high time complexity of existing distinguishing algorithms, and the need to manually adjust hyperparameters in different driving scenes, a three-branch lane instance segmentation algorithm is proposed in this paper, and the segmentation results are adaptively clustered to fit lanes of different instances. Considering the unbalanced characteristic of the image data obtained by the vehicle-mounted camera, a convolutional neural network is trained on the basis of the Tversky Loss function of the three-section field of view method. In view of the large curvature radius of the lane, the weight of the higher-order term is used as the regular term of a least square method to fit lanes. The test results on the TuSimple dataset show that the accuracy of the algorithm in identifying the lane of the considered example is 96.23%. Compared with LaneNet, the time complexity of the algorithm is reduced by 23.67%. Additionally, it has a good detection effect for various vehicle driving scenes.

**Key words** machine vision; convolutional neural network; lane detection; instance segmentation; adaptive clustering

**OCIS codes** 150.1135; 150.5758; 200.4560

收稿日期: 2020-08-25; 修回日期: 2020-09-22; 录用日期: 2020-10-14

\* E-mail: 305655539@qq.com

## 1 引言

近年来随着人工智能技术的发展,传统汽车工业与计算机技术紧密结合,使自动驾驶技术得到了迅速发展。自动驾驶技术最重要的任务之一就是理解对车辆行驶环境的理解,而车道线检测是理解车辆行驶环境的基础。许多辅助驾驶功能,如车道偏离预警、车道保持都是在车道线检测技术基础上拓展开发的。目前,车道线检测技术可分为基于传统视觉和基于卷积神经网络(CNN)两类算法。

基于传统视觉的车道线检测算法<sup>[1]</sup>一般分为边缘检测、车道线拟合和车道线跟踪三个步骤。该算法依赖图像特征的选取计算,当路面情况复杂、天气或光照条件较差、车道线存在缺失或遮挡时,很难提取到车道线的结构特征。对道路图像进行自适应分割<sup>[2]</sup>或利用红外滤光系统<sup>[3]</sup>检测车道线,可解决光照、遮挡等问题,提高传统车道线检测算法的抗干扰能力。CNN 通常利用卷积、池化等操作组成深层网络提取图像的大尺寸特征,采用编码-解码结构获取图像的语义分割结果。编码网络由上采样层和卷积层构成,与大多数分类网络如 VGGNet (Visual geometry group network)<sup>[4]</sup>和残差网络(ResNet)<sup>[5]</sup>类似。相比基于传统视觉的算法,基于 CNN 的车道线检测算法能自动根据图像的信息提取车道线特征,提高车道线特征提取的准确率,且对复杂行驶环境的鲁棒性较好。

Lee 等<sup>[6]</sup>为了解决极端天气下车道和路面标志的检测问题,设计了基于道路消失点的 VPGNet (Vanishing point guided network)算法,并对车道进行网格标记。相比像素标记的车道,该算法可以减少网络的计算量。Pan 等<sup>[7]</sup>为了解决车道线识别不连续的问题,设计了空间 CNN(SCNN)模块,采用与 ResNet 相同的原理进行图像上下左右的特征信息传递,并用语义分割的方式对图像像素进行多

分类。该算法将车道线实例分割问题转化为对每个像素点的多分类问题,避免了车道线后处理部分对识别结果的不良影响,但只能检测指定数量的车道线,且 SCNN 模块的计算时间较长。Neven 等<sup>[8]</sup>基于实例分割的思想提出了一种双分支的车道线检测网络 LaneNet,用 E-Net (Efficient neural network)<sup>[9]</sup>作为主干网络,通过语义分割分支识别车道线,并利用 Mean shift 算法对实例分割分支结果进行聚类,得到不同的车道线实例,然后通过透视变换网络(H-Net)进行车道线拟合。但该算法的主干网络比较复杂,聚类算法的时间复杂度高且存在大量超参数,对不同行驶环境的适应性较差。

针对车道线检测算法时间复杂度高、不同行驶场景需人为调整超参数等问题,提出了一种基于三分支的车道线实例分割算法。首先利用基于三分视野法的损失函数对 CNN 进行训练,然后对分割结果进行自适应聚类,最后将高次项权重作为最小二乘法正则项拟合不同实例车道线。

## 2 基本原理

以车道线为研究对象,提出了一种三分支车道线实例分割算法,其原理如图 1 所示。其中,语义分割分支提取车道线特征,得到语义分割的二值结果;实例分割分支将背景和不同车道线视作不同的类,将其特征映射到高维空间;车道线数量预测分支对环境中的车道线数量进行预测。三分支车道线实例分割算法根据语义分割的二值结果提取实例分割结果中所有车道线位置像素的高维空间映射特征;以预测的车道线数量为监督信息,对高维空间映射特征进行  $K$  均值( $K$ -means)聚类,实现自适应聚类;将聚类结果映射回图像平面,实现不同车道线的实例分割;再进行车道线最小二乘法拟合,获取车道线信息并去除异常识别点。

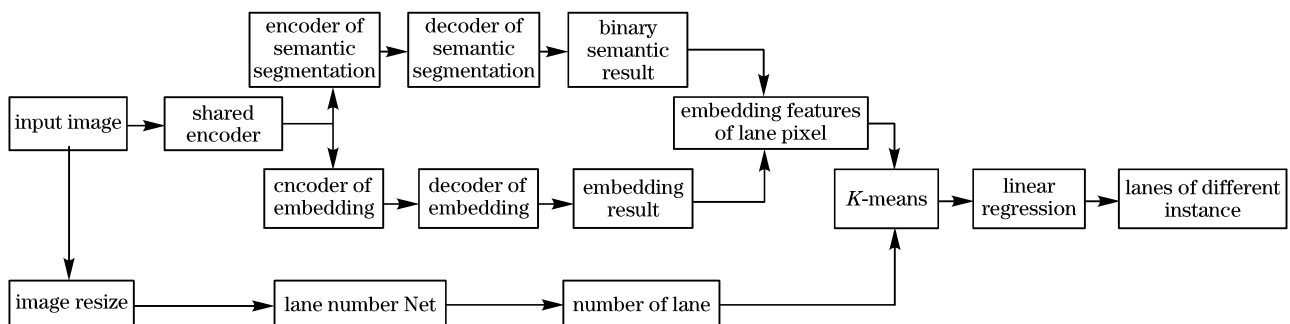


图 1 三分支车道线实例分割算法的流程图

Fig. 1 Flow chart of the three-branch lane instance segmentation algorithm

### 2.1 语义分割分支

语义分割分支网络采用改进的 DeepLabV3+<sup>[10]</sup> 网络,其结构如图 2 所示。其中,以 U-Net<sup>[11]</sup> 为代表的特征金字塔(FPN)编码-解码结构可将网络提取的浅层信息和深层信息进行融合,但增加了网络

结构的复杂度,如图 2(a)所示;空洞空间卷积池化金字塔(ASPP)结构将 1/16 特征图以不同膨胀率的空洞卷积进行并行采样,然后进行 4 倍上采样,与 1/4 特征图进行浅层信息与深层信息的融合,如图 2(b)所示。

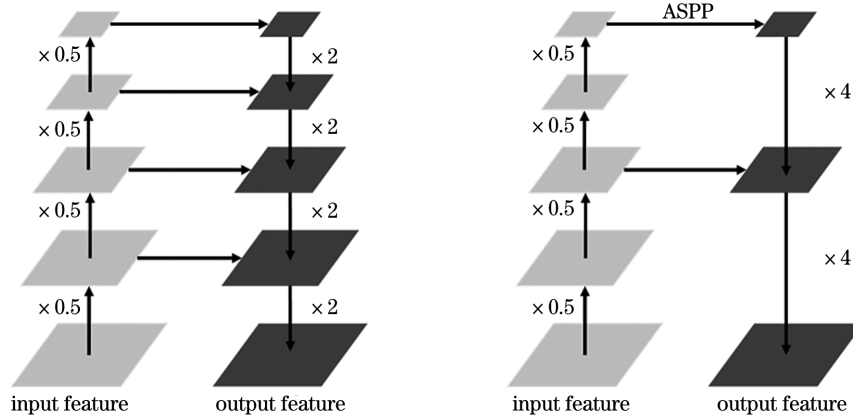


图 2 DeepLabV3+网络的结构。(a) FPN 的编码-解码结构;(b) DeepLabV3+网络

Fig. 2 Structure of the DeepLabV3+ network. (a) Encoding-decoding structure of the FPN ; (b) DeepLabV3+ network

DenseASPP<sup>[12]</sup> 是基于深度卷积网络(DenseNet)<sup>[13]</sup> 提出的改进 ASPP 结构,其结构如图 3 所示。DenseASPP 利用更密集的不同膨胀率空洞卷积进行组合级联,可在获得更大感受野的同时以非常密集的方式提取图像特征。由于车道

线具有细长且局部集中的特点,因此该结构有利于车道线特征的提取。考虑到密集连接会导致特征层的通道数急剧增长,用多个卷积核大小为 1×1 的卷积层进行通道调整,限制模型的大小与计算量。

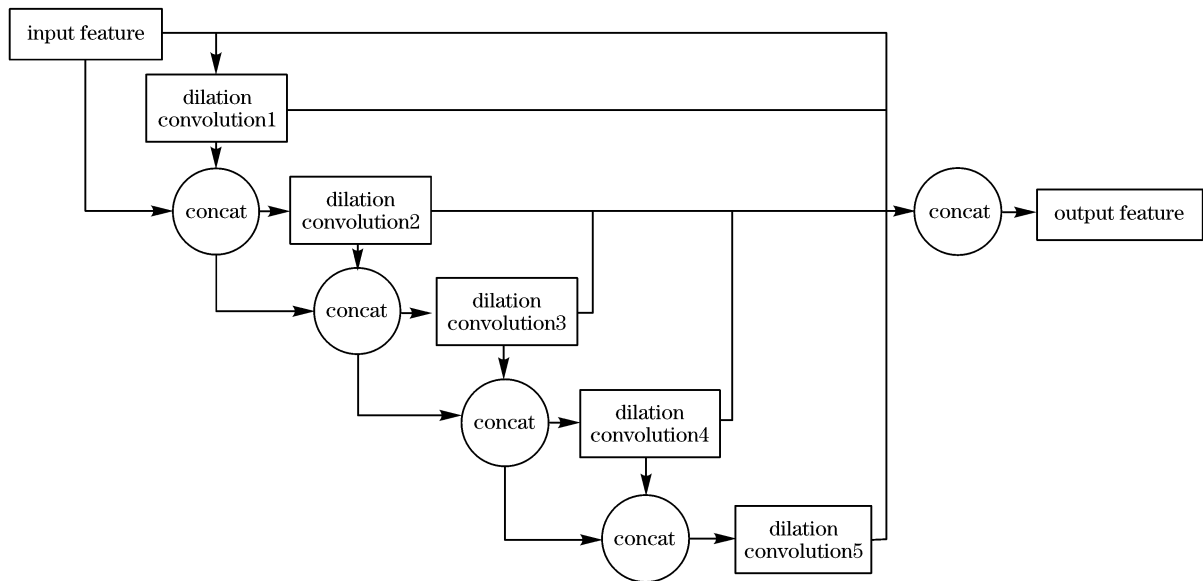


图 3 DenseASPP 的结构

Fig. 3 Structure of the DenseASPP

用基于 DenseASPP 改进的 DeepLabV3+ 网络作为语义分割网络,其结构如图 4 所示。以尺寸为 256 pixel × 512 pixel 的图像作为输入,经过卷积层+批归一化(BN)层+修正线性单元(ReLU)组成的卷积模块计算得到 1/16 特征图,经 DenseASPP

模块获得尺度更大、更密集的特征,经过卷积和上采样组成的上采样模块得到深层网络的 1/4 特征图,与浅层网络的 1/4 特征图进行通道融合,最后经上采样模块和 Softmax 层得到语义分割的二值结果。

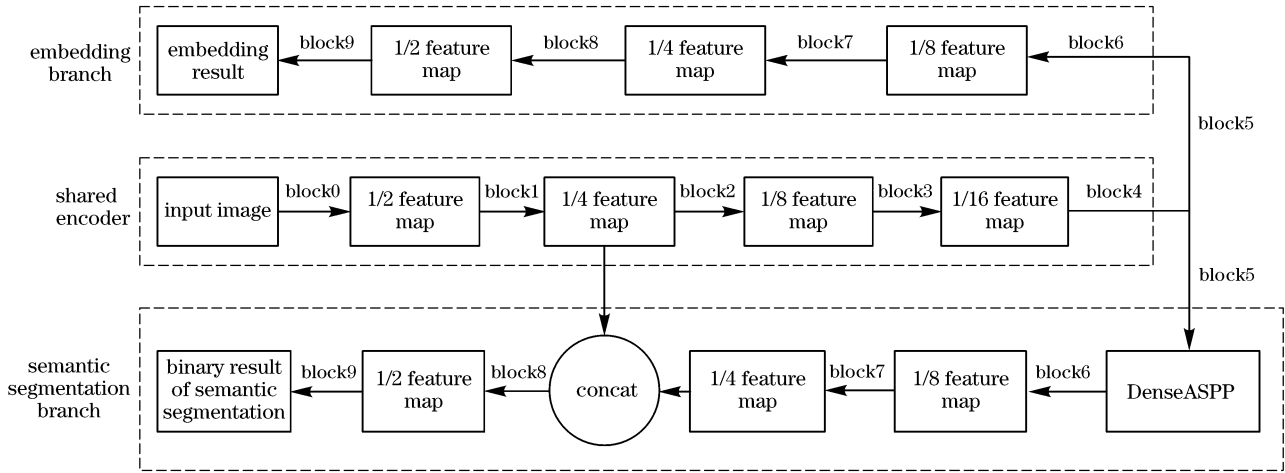


图 4 三支车道线实例分割网络的结构

Fig. 4 Structure of the three-branch lane instance segmentation network

Tversky Loss<sup>[14]</sup> 是基于图像分割领域中交并比 (IOU) 的损失函数, 针对性解决了图像分割中样本数据不平衡的问题。通过调整参数  $\alpha$  和  $\beta$  控制假正例和假负例之间的比例, 当  $\alpha=0.3, \beta=0.7$  时, 网络可获得最佳性能。Tversky Loss 虽然牺牲了部分精确率 (Precision), 但提高了召回率 (Recall), 在小病灶医疗图像分割领域的效果较好, 可表示为

$$T(\alpha, \beta) = 1 - \frac{\sum_{i=1}^N p_{oi} g_{oi}}{\sum_{i=1}^N p_{oi} g_{oi} + \alpha \sum_{i=1}^N p_{oi} g_{li} + \beta \sum_{i=1}^N p_{li} g_{oi}}, \quad (1)$$

式中,  $N$  为图像中像素点总数,  $p_{oi}, p_{li}$  分别为第  $i$  个像素点预测为正、负样本的概率,  $g_{oi}, g_{li}$  分别为第  $i$  个像素点实际为正、负样本的概率。

车道线图像分割与小病灶医疗图像分割具有类似的图像数据不均衡特点, 关注对象仅占据图像的小部分, 因此用 Tversky Loss 作为损失函数进行语义分割。车载摄像头采集的车辆行驶环境图像遵循透视原理, 具有近大远小的特点, 且车道线集中分布于图像下部分, 因此, 提出了一种基于三分视野法的 Tversky Loss, 可表示为

$$L_{\text{segmentation}} = 1 - \frac{\sum_{i=1}^N p_{oi} g_{oi}}{\sum_{i=1}^N p_{oi} g_{oi} + \alpha \sum_{i=1}^N p_{oi} g_{li} + \beta \sum_{i=1}^N p_{li} g_{oi}}, \quad (2)$$

式中,  $N_1, N_2, N_3$  为图像上、中、下各部分的像素点总数,  $w_1, w_2, w_3$  为图像上、中、下各部分的权重,

$L_{\text{segmentation}}$  为语义分割损失函数。

行驶环境图像下部分割结果对损失函数的影响较大, 图像上部分割结果对损失函数的影响较小, 因此, 取 (2) 式中的超参数  $w_1=0.8, w_2=1.0, w_3=1.2, \alpha=0.3, \beta=0.7$ 。将基于三分视野法的 Tversky Loss 函数用于语义分割网络的训练, 可提高近距离车道线识别的准确率。

## 2.2 实例分割分支

Brabandere 等<sup>[15]</sup> 提出了一种基于度量学习的实例分割算法, 通过自定义损失函数训练 CNN 学习一种度量标准, 将待提取像素空间内像素点的特征映射到高维空间, 使同类或同实例的像素点映射到高维空间后的距离相近, 不同类或不同实例的像素点映射到高维空间后的距离较远。自定义损失函数可表示为

$$L_{\text{var}} = \frac{1}{C} \sum_{c=1}^C \frac{1}{S_c} \sum_{i=1}^{S_c} [\|\mu_c - x_i\| - \delta_v]_+^2, \quad (3)$$

$$L_{\text{dist}} = \frac{1}{C(C-1)} \sum_{c_A=1}^C \sum_{\substack{c_B=1 \\ c_B \neq c_A}}^C [2\delta_d - \|\mu_{c_A} - \mu_{c_B}\|]_+^2, \quad (4)$$

$$L_{\text{reg}} = \frac{1}{C} \sum_{c=1}^C \|\mu_c\|, \quad (5)$$

$$L_{\text{instance}} = \varphi L_{\text{var}} + \phi L_{\text{dist}} + \gamma L_{\text{reg}}, \quad (6)$$

式中,  $C$  为实例总数 (车道线数量),  $S_c$  为该实例像素点总数,  $\mu_c$  为该实例所有像素点在映射空间的中心位置,  $x_i$  为该实例第  $i$  个像素点在映射空间的位置,  $c_A, c_B$  为不同实例,  $\|\cdot\|$  为 L2 距离,  $[x]_+ = \max(0, x)$ ,  $L_{\text{var}}$  为方差损失,  $L_{\text{dist}}$  为距离损失,  $L_{\text{reg}}$  为正则项,  $L_{\text{instance}}$  为实例分割损失函数, 超参数  $\delta_v=0.5, \delta_d=3.0, \varphi=\phi=1, \gamma=0.001$ 。

基于上述方法设计实例分割分支,由于实例分割与语义分割结果具有一部分相同的特征,因此实例分割分支与语义分割分支共享部分编码网络。实例分割分支也拥有部分独立编码网络和独立解码网络,实例分割分支与语义分割分支网络结构基本相似,不同点在于实例分割网络最后卷积层的卷积核个数为高维映射空间的维数,实验中取映射空间维度  $X_{space} = 4$ 。

### 2.3 车道线数量预测分支

车道线数量预测网络为分类 CNN,最后一层全

连接层神经元的个数为最大可检测车道线数量加 1,表 1 为该分支网络的详细信息。由于该分支与语义分割分支、实例分割分支无共享网络层,互不影响,因此输入图像的尺寸可与其他两个分支不同。为尽可能提高网络的运算速度,将其他两个分支输入图像的尺寸缩小为原始尺寸的 1/4 作为该分支的输入图像;为满足道路识别的实时性要求,该分支的卷积层均采用深度可分离卷积,从而将网络的参数量缩减为原来的 1/8 左右。本算法选取最大的可检测车道线数量  $X_{Max} = 5$ 。

表 1 车道线数量的预测分支网络

Table 1 Predictive branch network for the number of lanes

Structure	Convolution kernel number	Convolution kernel size/stride	Output size
Separable convolution+BN+ReLU	16	3×3	64×128
Separable convolution+BN+ReLU	16	3×3	64×128
Maxpool		2×2/2	32×64
Separable convolution+BN+ReLU	32	3×3	32×64
Separable convolution+BN+ReLU	32	3×3	32×64
Maxpool		2×2/2	16×32
Separable convolution+BN+ReLU	64	3×3	16×32
Separable convolution+BN+ReLU	64	3×3	16×32
Maxpool		2×2/2	8×16
Separable convolution+BN+ReLU	128	3×3	8×16
Separable convolution+BN+ReLU	128	3×3	8×16
Maxpool		2×2/2	4×8
Global_avgpool		4×8	1×1
Separable convolution+BN+ReLU		1×1	$X_{Max} + 1$

预测分支的损失函数用多分类交叉熵函数,由于车道线数量在训练集中存在分布不均匀的问题,因此需要增加权重。带权重的多分类交叉熵函数可表示为<sup>[9]</sup>

$$L_{num} = - \sum_{m=0}^{X_{Max}} v_m r_m \ln(q_m), \quad (7)$$

$$v_m = \frac{1}{\ln(b + p_m)}, \quad (8)$$

式中,  $r_m$  为图像实际含有  $m$  条车道线的概率,  $q_m$  为图像预测含有  $m$  条车道线的概率,  $p_m$  为图像实际含有  $m$  条车道线的情况占所有情况的百分比,  $v_m$  为  $m$  条车道线的情况对应的权重,  $L_{num}$  为车道线数

量预测损失函数,超参数  $b = 1.02$ 。

### 2.4 自适应聚类与拟合算法

LaneNet 采用 Mean shift 或 DBSCAN (Density-based spatial clustering of applications with noise) 作为聚类算法,该算法的优点是可在无聚类数量作为监督信息的情况下,确定聚类数量并完成聚类。两种聚类算法的时间复杂度均为  $O(p^2)$ ,其中  $p$  为数据量增大的倍数,时间消耗较大,降低了整体算法的实时性;且超参数的选择对于聚类结果的影响极大,需选择最优的超参数,降低了该算法对不同行驶环境的适应性。因此,提出了一种自适应聚类方法,将车道线数量预测网络的结果作为聚类算法的监督

信息,提取语义分割二值结果中车道线位置的高维空间映射特征,对高维特征进行  $K$ -means 聚类。将聚类结果映射回图像平面,实现不同车道线的实例分割。再对车道线实例分割结果中不同车道线进行最小二乘法拟合,获取每一条车道线的信息,并通过拟合去除语义分割网络的误检点。自适应聚类算法的时间复杂度为  $O(p)$ ,且不需要其他超参数,降低了聚类算法的时间消耗,且鲁棒性较高。

为防止后处理过程中产生的过拟合现象对图像识别结果的影响并去除车道线误检点,针对大部分车道线具有大曲率半径的特点,将车道线方程中的高次项系数作为正则项引入最小二乘法,用多项式拟合车道线方程,最小二乘法损失函数可表示为

$$L_{\min\_square} = \sum_{i=1}^{N_{\text{pixel}}} [f(u_i) - v_i]^2 + \lambda \sum_{j=2}^M \|a_j\|, \quad (9)$$

式中,  $N_{\text{pixel}}$  为车道线像素点个数,  $u_i$ 、 $v_i$  为第  $i$  个像素点的横纵坐标,  $f(x)$  为拟合车道线的曲线方程,  $M$  为车道线方程的最高次项,  $a_j$  为车道线方程中高于或等于二次项的权重,  $\lambda$  为可调节的参数。

### 3 分析与讨论

为验证本车道线实例分割算法的有效性,用车道线检测公开数据集 TuSimple 进行验证。TuSimple 数据集是图森未来在 2018 年车道线挑战赛中公开的数据集,主要行驶场景为多车道的高速公路。该数据集共有 3626 张训练图像和 2782 张测试图像,图像的分辨率为 720 pixel  $\times$  1280 pixel,所有图像均在较好和稍好天气情况下采集,标注信息为一定间隔的车道点。

算法测试评价指标采用 TuSimple 车道线挑战赛数据集的评价指标,将准确率(Accuracy)作为主要评价指标,误检率(FP)和漏检率(FN)作为辅助评价指标。TuSimple 数据集标注方式为离散的车道点坐标,以每张图像平均预测正确的车道点数量计算准确率,可表示为

$$X_{\text{Accuracy}} = \sum_l \frac{c_l}{s_l}, \quad (10)$$

式中,  $c_l$  为正确预测的车道点数量,  $s_l$  为真实标签中车道点的数量,  $l$  为车道线数量。当预测的车道点与真实车道点之间的距离小于设定阈值时,认为该车道点预测正确。

如果有一条车道线预测正确的车道点数量超过某一设定阈值,则认为真实车道线被检测到且该车道线预测正确;否则,认为该车道线预测错误。FP

和 FN 可表示为

$$X_{\text{FP}} = \frac{F_{\text{pred}}}{N_{\text{pred}}}, \quad (11)$$

$$X_{\text{FN}} = \frac{M_{\text{pred}}}{N_{\text{gt}}}, \quad (12)$$

式中,  $F_{\text{pred}}$  为预测错误的车道线数量,  $N_{\text{pred}}$  为预测的车道线总数量,  $M_{\text{pred}}$  为没有预测到但真实存在的车道线数目,  $N_{\text{gt}}$  为标签中所有的车道线数量。

在 Core-i7-9700 CPU, GTX1660Ti GPU 环境下,基于 Python-3.7、Tensorflow\_gpu-2.1.0、cuda-10.1.243、cudnn-7.6.5 以及函数库 Opencv\_python-3.4.2、Numpy-1.18.5、Matplotlib-3.2.2 和 Scikit\_learn-0.23.1 进行了车道线实例分割算法的测试。将样本训练集和验证集送入三支网络中进行训练和验证,并送入 LaneNet 双分支网络进行对比。实验参数:输入图像的尺寸为 256 pixel  $\times$  512 pixel,批处理大小为 8,基础学习率为  $e^{-4}$ ,学习动量为 0.9,权重衰减为 0.0001,训练至收敛为止。图 5、图 6 为训练过程中训练集与验证集损失值和准确率的变化趋势,表 2 为本算法与其他车道线检测算法在 TuSimple 车道线测试集上的效果。




图 5 训练集与验证集的损失

Fig. 5 Loss of training set and validation set

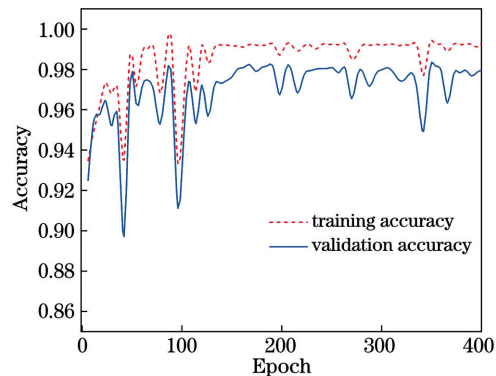


图 6 训练集与验证集的准确率

Fig. 6 Accuracy of training set and validation set

表 2 不同算法的精度

Table 2 Accuracies of different algorithms unit: %

Algorithm	Accuracy	FP	FN
Ref. [7]	96.53	6.17	1.80
Ref. [16]	96.50	8.51	2.69
Ref. [8]1	96.40	7.80	2.44
Ref. [17]	95.24	11.94	6.20
Ref. [8]2	96.20	23.58	3.62
Ours	96.23	8.34	7.29

为验证本算法的时间消耗, 将本算法与以 E-Net 为主干网络, Mean shift 为聚类算法的

LaneNet 所用的时间进行对比。每次处理 1 张图像, 共处理 1000 张图像, 单张图像的平均消耗时间如表 3 所示。可以发现, 本算法主要在聚类方式上进行改进, 降低了时间复杂度, 相比 LaneNet 使用的时间, 减少 23.67%。将本算法得到的最终模型应用于 TuSimple 测试集, 并对车道线的检测效果进行可视化, 选取三车道(直道)、四车道(弯道)、车辆遮挡、光影遮挡 4 种交通场景, 结果如图 7 所示。其中, ①、②、③、④分别为不同的实例车道线。可以发现, 在高速公路场景下, 本算法可用较短的时间高精度检测不同实例车道线。

表 3 不同算法的运行时间

Table 3 Running time of different algorithms

unit: ms

Algorithm	LaneNet		Ours	
	Module	Time	Module	Time
Network inference	E-Net	80	DeepLabV3+ with DenseASPP	76
Cluster	Mean shift	85	K-means with lane number branch	49
Lane fitting	Least squares	4	Least squares	4
Sum		169		129



图 7 不同场景的检测结果。(a)三车道(直道);(b)四车道(弯道);(c)车辆遮挡环境;(d)光影遮挡环境

Fig. 7 Test results of different scenarios. (a) Three-lane (straight); (b) four-lane (curve); (c) vehicle occlusion environment; (d) light and shadow occlusion environment

## 4 结 论

针对无人驾驶汽车对行驶环境的感知问题,基于现有 CNN 提出了一种三支车道线检测算法。将深度学习方法与机器学习方法相结合,对车道线进行语义分割、实例分割、自适应聚类和最小二乘法拟合,以获取车道线信息。针对车载摄像头获取的图像数据不平衡特点,用基于三分视野法的 Tversky Loss 函数对 CNN 进行训练。在 TuSimple 数据集上的测试结果表明,本算法能适应各种车辆行驶场景,在直线、弯道、车辆遮挡或光影遮挡场景下具有较好的检测精度,且鲁棒性强、检测速度快。

### 参 考 文 献

- [1] Gooch A A, Olsen S C, Tumblin J, et al. Color2Gray [J]. *ACM Transactions on Graphics*, 2005, 24(3): 634-639.
- [2] Ge P S, Guo L, Qi G D, et al. Lane marker line identification method in variable light environment [J]. *Laser & Optoelectronics Progress*, 2020, 57(16): 161502.  
葛平淑, 郭烈, 齐国栋, 等. 变光照环境下车道标识线的识别方法 [J]. *激光与光电子学进展*, 2020, 57(16): 161502.
- [3] Cheng C Y, Huang Y B, Lu X, et al. Lane detection based on active infrared filter and around-view imaging [J]. *Laser & Optoelectronics Progress*, 2018, 55(12): 121014.  
成春阳, 黄渊博, 卢鑫, 等. 基于主动红外滤光环视成像的车道线检测算法 [J]. *激光与光电子学进展*, 2018, 55(12): 121014.
- [4] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2020-08-03]. <https://arxiv.org/abs/1409.1556>.
- [5] 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.
- [6] 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.
- [7] Pan X G, Shi J P, Luo P, et al. Spatial as deep: spatial CNN for traffic scene understanding [EB/OL]. [2020-08-01]. <https://arxiv.org/abs/1712.06080>.
- [8] 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.
- [9] Paszke A, Chaurasia A, Kim S, et al. ENet: a deep neural network architecture for real-time semantic segmentation [EB/OL]. [2020-08-03]. <https://arxiv.org/abs/1606.02147>.
- [10] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [EB/OL]. [2020-08-05]. <https://arxiv.org/abs/1802.02611>.
- [11] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W, et al. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science. Cham: Springer, 2015, 9351: 234-241.
- [12] Yang M K, Yu K, Zhang C, et al. DenseASPP for semantic segmentation in street scenes [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3684-3692.
- [13] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [14] Salehi S S M, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional deep networks [EB/OL]. [2020-08-01]. <https://arxiv.org/abs/1706.05721>.
- [15] Brabandere B D, Neven D, Gool L V. Semantic instance segmentation with a discriminative loss function [EB/OL]. [2020-08-01]. <https://arxiv.org/abs/1708.02551>.
- [16] Hsu Y C, Xu Z, Kira Z, et al. Learning to cluster for proposal-free instance segmentation [C] // 2018 International Joint Conference on Neural Networks (IJCNN), July 8-13, 2018, Rio de Janeiro, Brazil. New York: IEEE Press, 2018: 1-8.
- [17] Pizzati F, Allodi M, Barrera A, et al. Lane detection and classification using cascaded CNNs [EB/OL]. [2020-08-01]. <https://arxiv.org/abs/1907.01294>.