

DOI: 10.13382/j.jemi.B1902877

基于 MultiRes+UNet 网络的车道线检测算法*

李梅梅^{1,2} 胡春海² 龙平¹ 刘少楠¹

(1. 东北大学秦皇岛分校 计算机与通信工程学院 秦皇岛 066004; 2. 燕山大学 电气工程学院 秦皇岛 066004)

摘要:无人驾驶技术改变人类生活方式,带车道线属性的高精地图,是无人驾驶领域的重要一环。针对现有算法在车道线检测时存在准确率低、效率低等问题提出基于 MultiRes+UNet 检测方法。该方法通过空洞卷积扩大卷积感受野,从而对全局信息统筹,运用 MultiRes block 和 Res path 结构减轻编码器-解码器特征之间的差异,大大降低了内存的需求。实验结果表明,此算法在保证检测准确率的同时,提高了算法的稳定性和运行速率,在纯车道、复合车道、阴影污损车道等多情况下,调和平均值分数分别为 0.959、0.942、0.891,该算法存在高效性、高鲁棒性。

关键词: 车道线检测; MultiRes+UNet 网络; 空洞卷积; 深度学习

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Lane line detection algorithm based on MultiRes+UNet network

Li Meimei^{1,2} Hu Chunhai² Long Ping¹ Liu Shaonan¹

(1. School of Computer and Communication Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China;

2. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: Unmanned technology changes human lifestyle. The high-precision map with the lane line attribute plays a crucial role in the unmanned field. Proposing a detection method based on MultiRes + UNet network, aiming at the problem that the low accuracy and low efficiency of existing algorithms in the detection of composite lane lines. This method expands the convolution receptive field by dilated convolution to co-ordinate global information. The MultiRes block and Res path structure are used to reduce the difference between the encoder and decoder features, which greatly reduces the memory requirement. The experimental results show that the proposed algorithm improves the detection speed of the algorithm while ensuring the detection accuracy. When the pure lane, compound lane and shadow fouling lanes are obtained, the harmonic mean F1 scores are 0.959, 0.942, and 0.891, the algorithm is high efficiency and high robustness.

Keywords: lane detection; MultiRes+UNet network; dilated convolution; deep learning

0 引言

随着汽车工业技术和经济水平的快速发展,使得机动车的保有量快速上升^[1]。从而汽车驾驶的安全性成为人们最为关心的热点题之一,如何提高汽车安全系数是一件急需解决的问题。而当前自动驾驶技术作为一种缓解乃至解决该问题的重要技术手段,日益受到了人们的关注^[2]。随着深度学习技术的应用,人工智能行业发展

迅猛,立足人工智能的自动驾驶技术更是获得了学者和工业界的青睐^[3]。自动驾驶中最为重要的问题就是对交通场景的检测,而车道线检测又是其重点。传统的目标检测^[4]和图像的阈值分割方法^[5]在交通场景的检测上效果较差^[6],难以应用到实际生产中,而深度学习的出现,使得交通场景检测算法的研究有了新的方向。

关于车道线检测方法,国内外专家学者已取得一定的成果。主要分为基于传统的检测方法和基于深度学习的检测方法两类。传统的车道线检测方法通常采用道路

收稿日期: 2019-12-30 Received Date: 2019-12-30

* 基金项目: 国家自然科学基金(61601105, 61602099, 61701097)、河北省自然科学基金(F2016501073)资助项目

图像特征、几何特征等信息建模或利用车载传感器实现。文献[7]提出利用变内核的顶帽算法进行车道线分割,结合加权最小二乘法及随机投种法实现三车道识别。但该方法只对直线及较大曲率道路效果明显。文献[8]提出了基于粒子滤波方法进行车道线检测,利用 Catmull-Rom 样条曲线数学模型标定车道线。该方法在夜间、雨天等恶劣环境下检测性能较弱。文献[9-10]结合 Otau 算法和 Hough 变换较好实现在光线不均匀及夜间车道检测,但该方法只能选择固定区域进行提取。文献[11]考虑固定区域内的车道检测不适用于陡峭度较大的道路,提出了一种结合车道线颜色特征的动态 ROI 的漏斗检测算法,并在复杂光照环境下有良好的效果。文献[12]提出基于双 ROI 和变相位扫描的车道检测算法,双 ROI 提取独立的左右区域,加快了检测速度。取得更好的效果,但缺点是道路噪声,使算法的鲁棒强度不高。文献[13]提供基于有限端点和随机采样算法(RANSAC)的车道检测算法,但很难检测到受损和不稳定的交叉口,对复杂的路况检测效果较差。文献[14]用于自动驾驶中复杂车道线检测方法和地图匹配算法,提出了一种使用 LiDAR 结合 AVM 摄像机的车道标记检测算法。将上述两种车道检测方案融合,作为地图映像算法的一部分,并在一个独立的测试车上实现该算法。以上传统的车道线检测方法多通过全局、局部位置信息进行特征提取,无法实现对车道跟踪的功能,且大多算法都局限于特定的应用环境下。

近年来,随着深度学习在计算机视觉领域上的广泛应用,国内外学者相继提出多种基于深度学习的车道线检测方法。文献[15]提出将现有的卷积神经网络(CNN)模型能用于高速自动驾驶,得到端到端的 CNN 能够用于车道检测与分类。文献[16]用像素级特征描述上下文信息进行建模,并用增强算法选择用于检测车道标记的上下文特征。文献[17]将 CNN 和 RANSAC 算法结合从边缘图像来检测车道,采用 CNN 主要用于图像增强,此方法仅适用于路边树遮挡,栅栏或十字路口道等复杂场景。文献[18]介绍了一种 DVCNN,利用前视和俯视图像可排除误检和去除非车道结构的目标。文献[19]提出适用多目标深度卷积网络,其重点用于寻找车道的几何结构属性(如位置、方向)并结合 RNN 来检测车道线。然而上诉基于深度学习检测方法存在共性问题:均受限检测一个预训练的、固定数量的车道线,且无法处理车道变化;通过训练模型产生二值化后的车道线分割图型仍需分离到不同的车道实例中。

本文提出基于 MultiRes+UNet 网络的车道线检测方法。该网络模型目前在医学领域上得到较好的应用,本文将将其引入到车道线语义分割中,确保在道路平面变化下的车道线拟合仍具有高效性、高鲁棒性。首先,为扩大

卷积感受野保留更多细节信息引入空洞卷积;为解决 UNet 网络对图像尺度输入的多样性支持不足问题,模型中创新性的引入具有残差结构的 MultiRes 模块;为减轻编码器-解码器特征之间特征差异,模型中引入 Res path 结构,同时增强网络的非线性能力。基于 MultiRes+UNet 网络的检测算法相对于 UNet 网络^[20],同等环境下其准确率和检测速度,均有较明显的改进效果,较好实现了对车道线的检测。

1 MultiRes+UNet 网络

改进的 MultiRes+UNet 网络依然采用 UNet 基本构架。网络结构分成对称的两部分:从图像中提取空间特征的编码器(下采样),以及从编码特征构造分割图的解码器(上采样)。图 1 所示为 MultiRes+UNet 算法整体构架。该结构由空洞卷积、MultiRes 模块、Res Path 结构构成。为更好统筹图像全局信息,引入空洞卷积从而扩大感受野;网络中将 UNet 中所有模块转换成 MultiRes 模块,该模块通过多个 3×3 卷积块及残差连接的扩展,使网络具有更优良的局部拓扑结构,从而更好的处理尺寸问题。同时引入 Res Path,通过非线性操作减少编码器与解码器特征间产生的语义差距。

1.1 空洞卷积

在像素级的预测任务中,预测结果是端到端的像素级输出,且输出图像的尺寸应与输入图像保持一致。针对下采样会降低图像分辨率,丢失特征信息的问题,本文引入空洞卷积(dilated convolution),通过卷积时在卷积核元素之间塞入空格增大感受野,进一步提取不同尺度的特征,将不同尺度的特征进行融合,得到表现力更强的综合特征。从而更好地学习图像的全局信息,精确定位目标。本网络中 MultiRes block5 将常规卷积替换为空洞卷积。

二维空间的空洞卷积公式可表示为:

$$(F *_{l} k)(P) = \sum_{s+t=P} F(s) \cdot k(t) \quad (1)$$

式中: F 为输入的二维图像; s 为其定义域; l 为膨胀因子; $*_{l}$ 为空洞卷积; k 为核函数; P 为空洞卷积的定义域。

当模型中塞入 $d-1$ 个空格数时,空洞卷积的卷积核大小可表示为:

$$n = k + (k - 1) \cdot (d - 1) \quad (2)$$

式中: k 表示卷积核大小; d 为空洞卷积采样率。

空洞卷积后输出的特征图的大小可表示为:

$$o = \lfloor \frac{i - 2p - n}{q} \rfloor + 1 \quad (3)$$

式中: i 表示输入空洞卷积的大小; p 代表卷积过程中补零个数; n 为空洞卷积后新卷积核大小; q 为卷积步长。

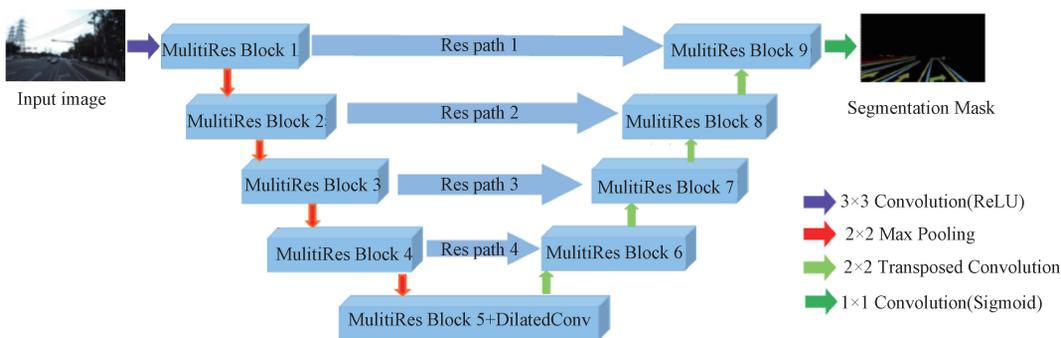


图 1 MultiRes+UNet 算法构架

Fig. 1 MultiRes+UNet algorithm architecture

1.2 MultiRes block+ Res path 结构

MultiRes block 如图 2 所示,该模块替换了 UNet 结构中的卷积层,以便在不同尺度上协调学习特征。其核心是使用一系列体积更小的 3×3 卷积块对 5×5 和 7×7 卷积层进行分解。第 2 和第 3 个 3×3 卷积块的输出分别有效地接近 5×5 和 7×7 卷积运算。从而减少网络参数的数目,提升网络的深度,加快网络的训练速度。从 3 个卷积块中获取输出并将它们串联,以提取不同尺度的空间特征。同时添加了 1 条用于保存尺寸的残差结构连接 (1×1) 的卷积核,最后使用 add 融合。通过该方法的改进,大大降低了内存的需求。

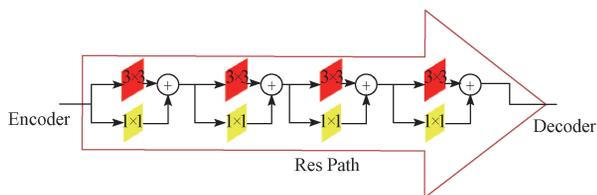


图 3 Res path 结构

Fig. 3 Res path frame

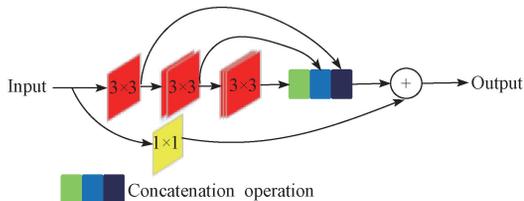


图 2 MultiRes block 结构

Fig. 2 MultiRes block frame

Res path 结构如图 3 所示,在 UNet 结构中采用快捷连接,使得网络能够从编码器传播到解码器,但在编码器中的特征由于卷积层数较浅(低层次的特征),而解码器中对应的特征由于卷积层更深(较高层次的特征),二者在语义上有较大差距,不宜直接将二者进行拼接。本结构中为了减轻编码器-解码器特征之间的差异,编码器的特征在与解码器中的对应特征连接之前,先进行了卷积操作。通过 3×3 卷积层与 1×1 残差结构的非线性操作,使编码器-解码器在连接前具有一致的深度,在 ResPath1、2、3、4 中分别使用 4、3、2、1 个卷积层。

2 实验与结果分析

本文的算法使用 python 作为开发语言,卷积神经网络

的建立、训练及测试均基于百度公司开发的 PaddlePaddle 框架;软件环境为 ubuntu-18.04.2-desktop-amd64,依赖 Python 3.6、opencv-python、paddlepaddle-gpu、imgaug,硬件环境为四核 i5-5200U@_2.20 GHz、8G RAM、NVIDIA GeForce 920 M。

2.1 算法评价标准

本文按照以下 3 个算法评价标准评定:是否有检测到车道、是否检测正确和算法运算时间。用来衡量前两个方面的分别是召回率 (RC) 和准确率 (PR),再综合召回率与准确率的调和平均 F_1 score 作为比较参数。计算公式分别为:

$$PR = \frac{TP}{TP + FP} \tag{4}$$

$$RC = \frac{TP}{TP + FN} \tag{5}$$

$$F_1 = 2 \times \frac{PR \times RC}{PR + RC} \tag{6}$$

式中: TP 表示网络正确检测到车道像素的点数; FP 表示网络错误检测到车道像素点的点数; FN 表示网络错误检测到非车道像素的点数。

2.2 数据集介绍

本文使用百度公司公开车道数据库进行训练,该数据集拥有较为精细车道标注数据图片共 5 600 张,分辨率为 3 384×690,记为 ColorImage_road,该训练集已除去较强曝光、车道不明显及全图车道极少的图片,所有图片

均以特定颜色标注了不同类型车道线结果。该训练集部分样本示例如图 4 所示。

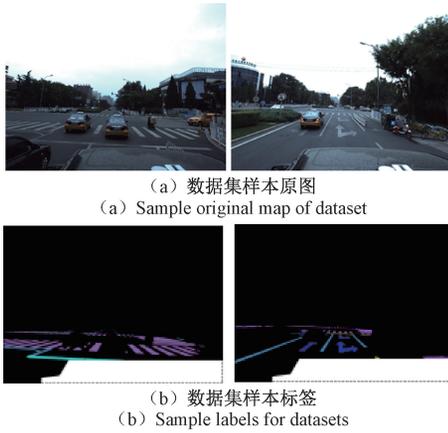


图 4 ColorImage_road 数据集
Fig. 4 ColorImage_road datasets

算法验证通过采集校园外街道 205 张照片作为测试集,标记为 test_road,该数据集具有较强的随机性,并包含磨损、理想、强光、阴影等特殊车道情况。

2.3 训练过程

训练集原像素为 3 384×1 710,为减小图像的压缩比例,提升整体的检测速度。考虑到原训练集上部分均为天空和树木,没有正样本的存在,训练前裁掉了 3 384×690 的图像。训练时采用了修改版的 Cycle LR 策略。采用收敛速度较快的 Adam。由于测试集与训练集在图像质量和视觉感知上存在较强的差异,太小的学习率很容易导致过拟合,因此采用 0.000 1 作为最小学习率。为保持图像比例均衡,每个阶段采用 768×256,1 024×384,1 536×512 三种分辨率进行训练,大分辨率的模型通过前 1 个小分辨率的预训练模型训练得到,此方法可以快速验证模型的有效性,并可以提供较好的特征分布;基于小分辨率的预训练,可以帮助大分辨率更好地进行收敛,同时大幅度提升网络针对输入图片分辨率的自适应性。

2.4 实验结果

本文使用相同车道线数据集对 UNet 神经网络及本文的 MultiRes+UNet 网络结构进行实验。训练后的网络模型分别对测试集中的图像进行车道线检测。

本文测试使用 i5-5200U_@_2.20 GHz、8G RAM 作计算单元,为提升测试效果,采用 iaa 的图像处理方式,从亮度、对比度、饱和度等方面对测试数据进行效果增强,以便得到更好的检测分割效果。测试集分为纯车道、复合车道(包括多种交通标示线,如匝道、斑马线、箭头、黄网格线等)、污损车道(受树荫遮挡、时间过长车道特征不清晰、有污水遮挡等其他污损的车道线)3 种类型共 205 张图片进行测试,部分测试结果如图 5 所

示,不难看出两种算法均可较为完整的检测纯车道线;对于复合车道分割结果,UNet 检测算法对箭头等复合车道线检测效果欠佳;针对污损车道线分割结果,由于污损影响,UNet 算法未能够对污损部分进行有效检测,而本文提出的 MultiRes+UNet 得到较好的检测效果。通过 2 个算法在 3 种车道线的测试结构比较,2 种算法均能检测出车道线,但是优化后的算法明显拥有较高的检测精度。

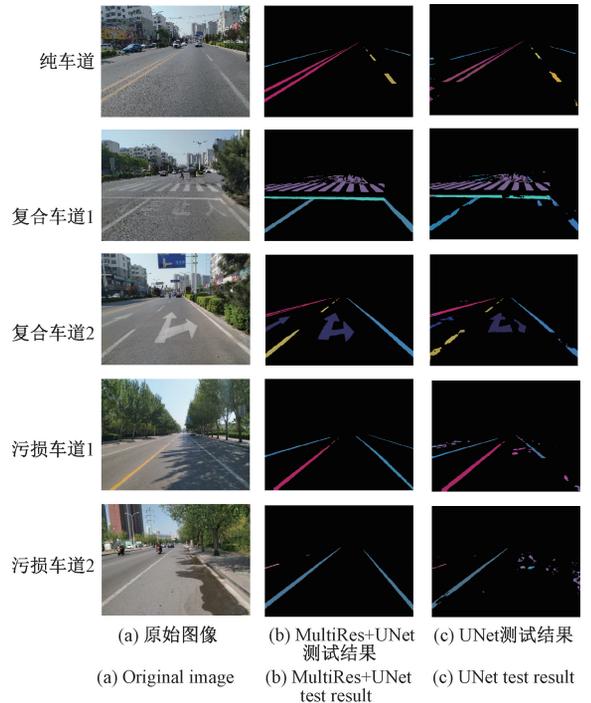


图 5 两种网络结构图像测试结果
Fig. 5 Two kinds of network structure test results

按照上文提出的算法评价标准,通过脚本计算两算法的召回率、准确率,综合调和平均 F_1 score,各算法测试结果如表 1 所示。通过测试结果可知 MultiRes+UNet 网络在各车道类型中 F_1 score 分数得分均高于基础 UNet 网络,MultiRes+UNet 网络在纯车道、复合车道、阴影污损车道中 F_1 score 分别为 0.959、0.942、0.891。

表 1 各算法测试结果

Table 1 Test results of each algorithm

车道类型	算法	召回率/%	准确率/%	F1 分数
纯车道	MultiRes+UNet	94.45	97.38	0.959
	UNet	90.87	96.14	0.934
复合车道	MultiRes+UNet	90.45	98.38	0.942
	UNet	80.50	93.44	0.865
阴影污损车道	MultiRes+UNet	86.05	92.33	0.891
	UNet	82.23	88.02	0.850

同时在表 2 得到两算法的运行时间,本文采用完成每张图片处理所需时间为标准。通过计算时间项可知 MultiRes+UNet 网络运算时间快于基础 UNet 网络,相对于 UNet 网络减少了 22.72% 的运行时间。

表 2 各算法运行时间

Table 2 Running time of each algorithm

算法	每张计算时间	单位
MultiRes+UNet	4.538 51	s
UNet	5.872 50	s

MultiRes+UNet 网络算法在利用深度学习进行对应数据集训练之后在检测新的环境车道时相对于 UNet 算法有着较高的召回率、准确率和鲁棒性,也将 UNet 算法运算时间减少 22.7%,由此可见经过本文 MultiRes+UNet 网络算法进行车道线检测有较高的适用性和实用性。

3 结 论

本文提出一种基于 MultiRes+UNet 网络的车道线检测算法。该方法通过引入空洞卷积,更好的统筹图像全局信息;引入 MultiRes 模块,更好处理尺寸问题;引入 Res Path,通过非线性操作减少编码器与解码器特征之间产生的语义差距。优化了计算性能,节约计算成本。实验结果表明,本文提出的算法在同等环境下其准确率和检测速度,均有较明显的改进效果,有效提高了车道线分割的准确度,较好的实现了对车道线的检测。

参考文献

[1] OZGUNA U, FAN R, AI X, et al. Multiple lane detection algorithm based on novel dense vanishing point estimation [C]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(3): 621-632.

[2] JUNG S, YOUN J, SULL S. Efficient lane detection based on spatiotemporal images[C]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(1): 289-295.

[3] HUANG CH T, HU ZH Q, SHI T. Traffic lane line classification system by real-time image processing[C]. 2018 International Automatic Control Conference (CACs), 2018: 1-6.

[4] 孙宇嘉,于纪言,王晓鸣. 适用于复杂场景的多目标跟踪算法[J]. 仪器仪表学报, 2019, 40(3): 126-137.

SUN Y J, YU J Y, WANG X P. Multiple object tracking

algorithm for the complex scenario[J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 126-137.

[5] NIU J, LU J, XU M, et al. Robust lane detection using two-stage feature extraction with curve fitting[J]. Pattern Recognition, 2016, 59: 225-233.

[6] ALY H, BASALAMAH A, YOUSSEF M. LaneQuest: an accurate and energy-efficient lane detection system[C]. 2015 IEEE International Conference on Pervasive Computing and Communications (PeCom), 2015: 163-171.

[7] 段建民,战宇辰,刘冠宇. 基于 TopHat 分割和曲线模型的三车道检测方法[J]. 北京工业大学学报, 2016, 42(8): 1174-1181.

DUAN J M, ZHAN Y CH, LIU G Y. Three-lane detection method based on topHat segmentation and curve models[J]. Journal of Beijing University of Technology, 2016, 42(8): 1174-1181.

[8] 陈孟元. 基于粒子滤波框架 Catmull-Rom 样条的多车道检测及跟踪算法研究[J]. 电子测量与仪器学报, 2015, 29(10): 1520-1528.

CHEN M Y. Study of multi-lane detection and tracking algorithm based on catmull-romspline and particle filter framework[J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(10): 1520-1528.

[9] 李亚娣,黄海波,李相鹏,等. 基于 Canny 算子和 Hough 变换的夜间车道线检测[J]. 科学技术与工程, 2016, 16(31): 234-237,242.

LI Y D, HUANG H B, LI X P, et al. Nighttime lane markings detection based on canny operator and hough transform [J]. Science Technology and Engineering, 2016, 16(31): 234-237,242.

[10] 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.

[11] 鱼兆伟,吴晓波,沈林. 基于动态感兴趣区域的光照无关车道线检测算法[J]. 计算机工程, 2017, 43(2): 43-47,56.

YU ZH W, WU X B, SHEN L. Illumination invariant lane detection algorithm based on dynamic region of interest[J]. Computer Engineering, 2017, 43(2): 43-47,56.

[12] 王鑫,刘玉超,海丹. 基于双重 ROI 和变间距扫描的车道线检测[J]. 指挥与控制学报, 2017, 3(2): 154-159.

WANG X, LIU Y CH, HAI D. Lane detection method based on double ROI and varied-line-spacing scanning[J]. Journal of Command and Control, 2017, 3(2): 154-159.

- [13] 王任栋, 李华, 赵凯, 等. 基于核密度估计的城市动态密集场景激光雷达定位[J]. 光学学报, 2019, 39(5): 341-350.

WANG R D, LI H, ZHAO K, et al. Robust localization based on kernel density estimation in dynamic diverse city scenes using lidar [J]. Acta Optica Sinica, 2019, 39(5): 341-350.

- [14] LEE H, KIM S, PARK S. AVM/LiDAR sensor based lane marking detection method for automated driving on complex urban roads [C]. IEEE Intelligent Vehicles Symposium, 2017: 1434-1439.

- [15] KIM J H, JANG G J, LEE M H. Fast learning method for convolutional neural networks using extreme learning machine and its application to lane detection[J]. Neural Networks, 2017, 87: 109-121.

- [16] GOPALAN R, HONG T, SHNEIER M. A learning approach towards detection and tracking of lane markings[C]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(3): 1088-1098.

- [17] KIM J, LEE M. Robust lane detection based on convolutional neural network and random sample consensus[C]. ICONIP, 2014: 454-461.

- [18] HE B, AI R, YAN Y. Accurate and robust lane detection based on dual-view convolutional neural network [C]. Intelligent Vehicles Symposium, 2016: 1041-1046.

- [19] LI J, MEI X, TAO D. Deep neural network for structural prediction and lane detection in traffic scene[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(3): 690-703.

- [20] LANDRY G, HANSEN D, KAMP F. Comparing Unet training with three different datasets to correct CBCT images for prostate radiotherapy dose calculations [J]. Physics in Medicine and Biology, 2019, 64(3): 11-35.

作者简介



李梅梅, 2014 年于燕山大学获得硕士学位, 现为东北大学秦皇岛分校实验师, 燕山大学博士研究生, 主要研究方向为计算机视觉-图像分割。

E-mail: limeimei@neuq.edu.cn

Li Meimei received her M. Sc. degree from Yanshan University in 2014. Now she is a laboratory teacher at Northeastern University at Qinhuangdao and Ph. D. candidate at Yanshan University. Her main research interests include machine vision.



胡春海(通信作者), 2004 年于燕山大学获得博士学位, 现为燕山大学教授, 博士生导师, 主要研究方向为计算机视觉-图像分割、图像处理等。

E-mail: 240844165@qq.com

Hu Chunhai (Corresponding author) received his Ph. D. Degree from YanShan University in 2004. Now he is a professor and Ph. D. supervisor at Yanshan University. His main research interests include machine vision-Image Segmentation and image processing, etc.



龙平, 2019 年于东北大学秦皇岛分校获得学士学位, 现为杭州海康威视数字技术股份有限公司工程师, 主要研究方向为计算机视觉-图像分割。

E-mail: longping@hikvision.com

Long Ping received his B. Sc. degree from Northeastern University in 2019. Now he is an engineer in Hangzhou Hikvision Digital Technology Co, Ltd. His main research interests include computer vision-image segmentation.



刘少楠, 2015 年于东北大学获得硕士学位, 现为东北大学秦皇岛分校实验师, 主要研究方向为计算机视觉-图像分割。

E-mail: liushaonan@neuq.edu.cn

Liu Shaonan received his M. Sc. degree from Northeastern University in 2015. Now he is a laboratory teacher at Northeastern University at Qinhuangdao. His main research interests include machine vision.