

doi: 10.11835/j.issn.1000-582X.2021.255

一种基于无人机影像的高精地图车道线检测与提取方法

吕可晶^{1,2}, 严虹¹

(1. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;
2. 中国科学院大学 资源与环境学院, 北京 100049)

摘要:高精度地图是实现自动驾驶技术必不可少的基础设施, 车道线是高精度地图车道级路网的重要组成部分。以往高精度地图的车道线检测多基于车载摄像头数据, 存在成像范围有限、需要透视变换和多次拼接造成的效率问题。基于无人机航拍影像, 采用 U-Net 网络识别道路区域, 过滤非道路区域噪声, 通过 HSL 颜色变换和 Sobel 算子分别计算车道线颜色和边缘梯度特征, 使用 Otsu 算法自动确定特征分割阈值获得二值化车道线特征图, 通过局部最大值算法确定滑动窗口的初始位置, 最后借助滑动窗口算法和多项式检测拟合车道线。实验结果表明, 在保证一定检测精度的前提下, 单条车道线检测长度超过了百米, 道路检测效率达到 25.2 m/s, 相比于地面影像的检测算法具有明显的效率优势。

关键词:高精度地图; 无人机影像; 车道线提取; U-Net; 视觉特征

中图分类号: P285.4

文献标志码: A

文章编号: 1000-582X(2022)08-141-10

A high definition map lane line detection and extraction method based on UAV images

LYU Kejing^{1,2}, YAN Hong¹

(1. State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, P. R. China; 2. College of Resources and Environment, University of Chinese Academy of Sciences, Beijing 100049, P. R. China)

Abstract: High definition map is an essential infrastructure to realize automatic driving technology, and lane line is an important part of lane level road network of high definition map. Currently, lane detection of high definition map is mostly based on the data of vehicle camera, which is low efficient due to limited imaging range and need for perspective transformation and multiple stitching. In this paper, based on UAV aerial images, U-Net network is used to identify road areas and filter noise in non-road areas. HSL color transform and Sobel operator are used to calculate lane color and edge gradient features respectively. Otsu algorithm is used to automatically determine feature segmentation threshold to obtain binary lane feature map. Local maximum algorithm is used to determine the initial position of sliding window. Finally, lane

收稿日期: 2021-03-17 网络出版日期: 2021-05-16

基金项目: 国家重点研发计划资助项目(2017YFB0503501)。

Supported by the National Key Research and Development Program of China(2017YFB0503501).

作者简介: 吕可晶(1995—), 男, 硕士研究生, 主要从事地图学研究, (E-mail) 1157529316@qq.com。

lines are fitted by sliding window algorithm and polynomial detection. The experimental results show that with certain detection accuracy, the detection length of a single lane line exceeds 100 m, and the road detection efficiency reaches 25.2 m/s. Compared with the lane line detection algorithms based on vehicle-mounted camera data, the proposed method is obviously more efficient.

Keywords: high definition map; UAV image; lane line extraction; U-Net; visual features

随着无人驾驶的兴起,以及其他基于位置的新型服务和行业的出现,使得地图的服务对象不再仅仅是人类,而是逐渐向机器过渡,这对地图的精度、内容结构和计算模式等都提出了新的要求^[1]。高精度地图作为实现无人驾驶中的重要环节,包含了丰富的动态信息,可以为无人驾驶提供精准的定位、辅助环境感知,同时提高无人驾驶的安全性^[2]。相比于传统的导航电子地图,高精度地图不仅要求亚米级的高精度绝对坐标,而且要能准确描绘道路形状、车道线、车道中心线和交通标志等道路交通信息元素,具备高精度(高精度地图数据精度)、高丰富度(高精度地图数据类型)、高实时性(高精度地图更新频率)等特点^[3]。车道线是自动驾驶高精度地图的重要组成部分,指示并约束车辆在车道中行驶,车道线检测成为高精度地图生产的重要环节之一。

目前,高精度地图的车道线检测多是采用车载单/多目摄像机传感器获取车道线信息,这类车道检测方法分为两类,一种是基于特征方法,通过分析图像的颜色、梯度以及边缘等低层次特征提取车道线^[4-6]。如:周宏宇等^[7]使用 Haar 特征提取车道线特征,选择 AdaBoost 分类器实现了较高的检测精度;易世春等^[8]利用图像梯度对道路有效边缘特征进行提取、聚类 and 分类形成车道线;另一种则利用卷积神经网络强大的特征提取能力进行车道线检测^[9-10]。如 Huval 等^[11]基于卷积神经网络进行车道线的检测;Neven 等^[12]设计了 LaneNet 和 H-Net 分支网络模型,预测转换矩阵 \mathbf{H} ,并使用转换矩阵 \mathbf{H} 透视变换到鸟瞰视图,对属于同一车道线的像素点进行聚类,实现了多条车道线端到端的检测。

但是这些基于车载影像的检测方法存在以下问题:1)地面摄像头的成像范围有限,单次检测覆盖范围过小,大规模检测时效率较低,不适合大规模的高精度地图制作;2)地面成像视角,使检测的车道线需要经过透视变换获得俯视图生成完整的高精度地图,透视变换会引入投影误差,当多张俯视图拼接时误差累计传递难以控制;3)地面影像采集设备依赖 GPS 和惯性导航设备获取坐标信息,定位信号的丢失会造成局部车道线位置信息丢失;4)地面数据采集车成本高、部署不便,高精度地图的每次更新都需要将采集设备发送到任务区,经济性不高,更新不灵活。

高分辨率遥感影像是地图绘制的重要数据源,利用高分辨率影像提取道路信息^[13-16],一直以来都是比较热门的研究课题,但受限于遥感影像的空间分辨率(大多为米以上),难以提取车道级信息(需要厘米级),此外遥感影像更新周期也不够灵活。相较于卫星遥感影像,无人机可以灵活获取厘米级精度的高分辨率影像,同时与车载摄像头相比,无人机具有成像视角和成像高度的优势,可以获得大范围的俯视图影像,是绘制更新高精度地图的理想数据源。但是由于无人机影像中非道路区域背景复杂,车道线目标狭小难以直接检测,目前基于航拍影像提取车道的研究很少,现有如:Azimi 等^[17]提出了一种 Aerial LaneNet 网络,基于全卷积网络直接从无人机影像检测车道线;Jin 等^[18]通过离散小波变换对无人机影像将分辨率处理,使用传统的阈值分割识别道路区域,过滤非车道区域的特征。

综上所述,基于车载影像检测车道线的方法不适用大规模高精度地图制作和更新,而卫星遥感影像方法受限于空间分辨率和更新周期,无法快速灵活获得车道级的信息。目前少量的基于无人机影像数据的车道检测研究,也存在以下问题:1)针对航拍影像的车道线检测数据集相对缺失,航拍影像中车道线目标较小容易造成样本不均衡,且航拍道路影像中道路路面具有相似性,难以产生差异性的样本集^[19],这直接影响深度学习方法的训练和检测效果;2)现有基于航拍影像提取车道线的研究,多使用传统方法识别道路区域,难以有效去除非道路区域噪声干扰。

针对这些问题,笔者提出了新的基于 U-Net 网络和图像视觉特征的解决方案。使用 U-Net 网络对无人机影像语义分割获取道路区域,再结合影像的视觉特征在道路区域内进一步检测车道线,实现基于无人机航拍影像的车道线提取。本方法的优点是:1)以无人机影像作为数据源,具有影像成像范围广和无须透视变换

的特点,避免了地面摄像头影像成像范围小,多次透视变换拼接误差累积的问题;2)采用深度学习 U-Net 网络识别道路区域,更好地解决非道路区域背景噪声影响;3)在道路区域内利用车道线颜色和结构特性检测车道线,不需要额外高质量的训练数据集。本研究中提出的车道线检测方法可以帮助高精度地图实现低成本、高效、灵活的绘制与更新。

1 技术路线

本文中基于无人机影像提取车道线的方法分为:道路区域识别、车道线特征提取和道路区域内的车道线检测,如图 1 所示。道路区域识别通过构建 U-Net 网络模型,并对其训练用以分割无人机航拍影像,识别出道路区域作为掩膜。道路区域内的车道线提取依赖于无人机影像的视觉特征,通过颜色空间变换提取图像颜色特征,使用 Sobel 算子提取车道线边缘方向的梯度,并借助道路区域掩膜过滤掉非道路背景噪声,使用 Otsu 算法对车道线颜色特征和梯度特征分割,获得二值化车道线特征图。车道线检测基于形态学滤波后的二值化特征图,使用滑动窗口算法实现车道线的定位并采用多项式拟合。

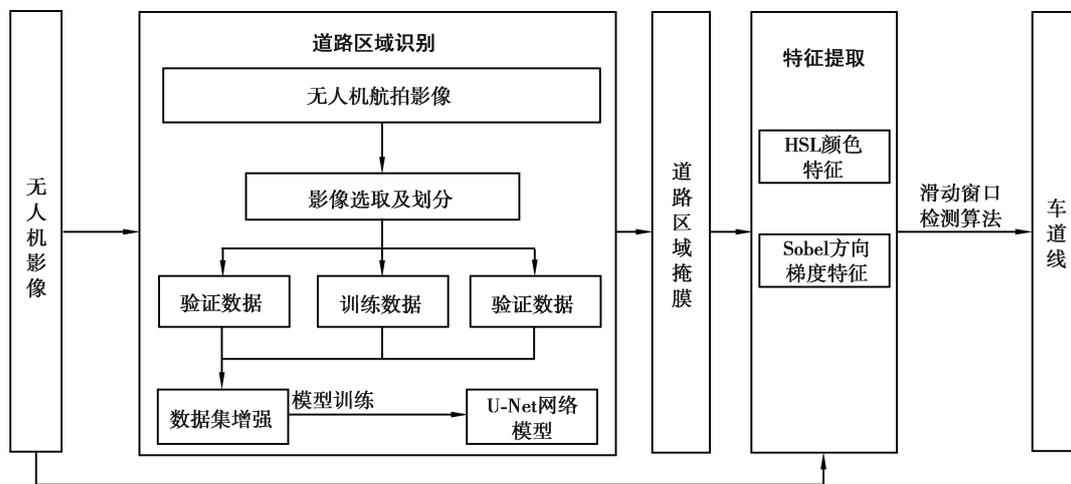


图 1 基于无人机影像提取车道线方法流程

Fig. 1 Flow chart of lane line extraction based on UAV image

2 研究方法

2.1 U-Net 网络结构

U-Net 网络^[20]建立在 FCN 网络基础之上,最初用来做医学图像的处理目前已广泛应用到遥感地物提取方面。U-Net 网络是一种 U 型编码器—解码器结构,与 CNN 等大多数网络类似,U-Net 网络主要由输入层、隐藏层、输出层构成。编码阶段图 2 左侧与 VGG 网络类似,主要由简单的卷积、池化下采样构成。采用的是 3×3 和 1×1 的卷积核进行卷积操作,其中 3×3 用于提取特征, 1×1 用于改变维度。将用于下采样的最大池化层尺寸设置为 2×2 ,获得包括输入的图像总计 5 个尺度。在解码阶段图 2 右侧进行上采样和多尺度特征融合,逐步恢复空间维度并修复物体的细节信息。U-Net 网络使用转置卷积卷积完成上采样,将编码阶段各个尺度的特征信息进行拷贝,分别叠加到解码阶段相对应的特征图中实现多尺度特征融合。对比于 FCN 的跃级结构不同,U-Net 网络特征融合的方式在 channel 维度进行拼接形成更厚的高维度特征,从而减少下采样过程中的信息损失,为特征图增加细节信息提高分割的精度。

随着网络层数的加深,激活函数输入值的分布在训练过程中会逐渐偏移,使得反向传播时低层的神经网络梯度消失。针对梯度消失问题,使用批标准化(batch normalization, BN),固定每层神经网络的输入分布,以此解决梯度弥散问题。

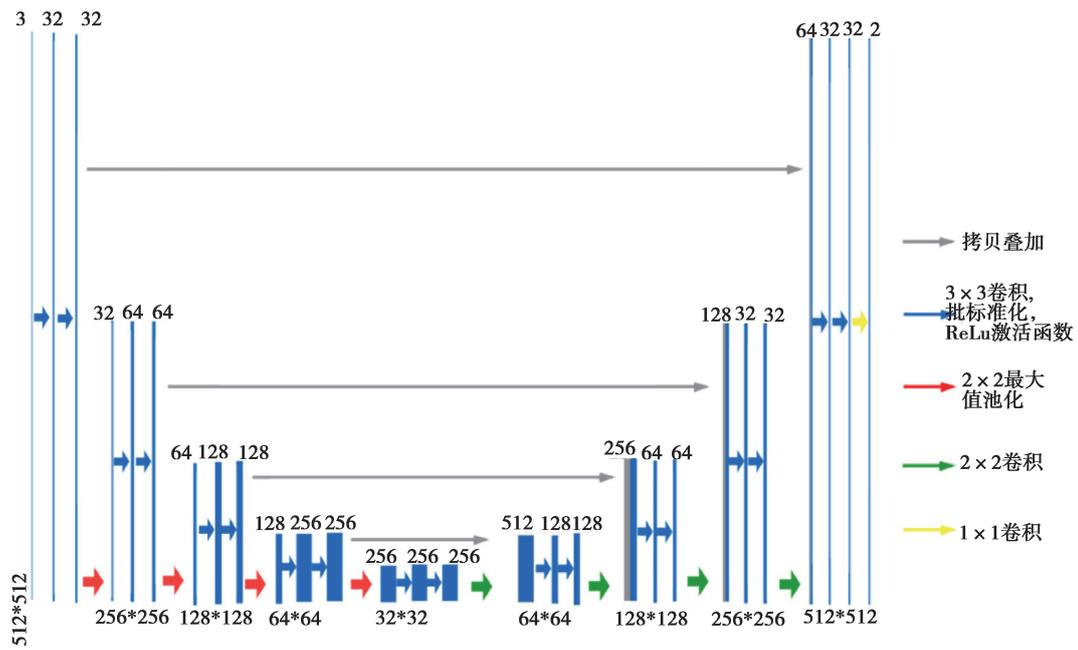


图 2 U-Net 网络模型结构

Fig. 2 Structure of U-Net

2.2 车道线视觉特征提取

我国对于车道线的线型、线宽、颜色等有明确的规定,相对于路面环境车道线的颜色特性和结构特性明显,根据这些特征即可实现车道线的检测和定位,使用梯度特征和颜色特征进行车道线检测。

2.2.1 颜色特征

低空无人机影像多采用 RGB 颜色模式,颜色空间是一种心理物理色的颜色系统,难以模拟人类对颜色的视觉感知,且不易分割和计算。根据《道路交通标志和标线》^[21]规定,我国的车道线为白色和黄色两种,在 HSL 颜色空间中白色和黄色的饱和度明显高于路面环境颜色,因此 HSL 颜色空间更适合分离车道线。HSL 空间以 S 分量表示饱和度,白色和黄色在 S 分量的值远大于路面颜色,根据 S 分量可以从路面区域中分离出车道线。

2.2.2 梯度特征

车道线相比于周围路面环境有着明显的梯度、灰度等边缘特征。常用的等边缘提取算法如 Canny 算法,提取车道线特征的同时,也会提取图像中其他方向无关的边缘梯度特征引入噪音。相对于 Canny 算子, Sobel 算子可以单独计算横向或者纵向的梯度,通过横向和纵向的梯度获得像素的梯度方向,因此使用 Sobel 算子来提取道路的边缘梯度特征。Sobel 算子求图像方向梯度的过程可以理解为求图像的 x 、 y 方向的一阶偏导数,为了简化计算往往使用离散差分算子来求得近似的梯度,如图 3 所示。

-1	0	+1
-2	0	+2
-1	0	+1

-1	-2	-1
0	0	0
+1	+2	+1

图 3 Sobel 算子

Fig. 3 Sobel operator

$$\theta = \arctan \frac{G_y}{G_x}, \tag{1}$$

式中: G_x, G_y 分别表示沿 x 和 y 方向的方向梯度, θ 表示梯度方向。

2.2.3 特征提取

路面背景下车道线视觉特征明显,因此使用阈值法分别从增强后的颜色和梯度特征图中提取车道线特征。阈值法的关键是选择一个合适的阈值,针对不同影像阈值多有差别,Otsu 算法可以通过最大化自动设置最佳阈值。

$$V(T) = \frac{(\bar{\mu} \cdot \omega(T) - \mu(T))^2}{\omega(T) \cdot \mu(T)}, \tag{2}$$

式中: $\omega(T) = \sum_{i=0}^T p_i, \mu(T) = \sum_{i=T+1}^{255} p_i, \bar{\mu} = \sum_{i=0}^{255} i \cdot p_i, p_i$ 表示灰度为 i 的像素概率值。单独使用颜色特征或梯度特征进行特征提取,会受限于复杂的路面情况造成缺失,这里将根据颜色和梯度特征提取的车道线特征联合,具体的联合方法为:

$$G_x \cup S_{HSL}, \tag{3}$$

式中: G_x 表示图像的横向梯度二值矩阵, S_{HSL} 表示 HSL 颜色空间 S 分量的阈值二值矩阵。

2.3 滑动窗口检测算法

基于车道线的颜色和梯度特征,采用滑动窗口算法来进一步检测车道线,算法流程如图 4 所示。首先,设定诸如滑动窗口尺寸、窗口内最少非零像素点数等参数,根据滑窗高度以及航拍影像的尺寸,计算出滑动窗口个数 n 。分别以各车道线的大致位置作为初始滑窗的下边界中点,保存窗口内的所有非零像素点的坐标,统计该窗口内的非零像素点个数并于阈值,若大于阈值计算滑窗内所有非零像素点的横坐标均值,作为下一个滑窗的下边界中点,该滑窗的上边界纵坐标始终作为下一个滑窗的下边界纵坐标,循环直至滑窗个数达到 n 完成该条车道线的滑窗检测。完成滑窗检测后,根据存储的滑窗中非零像素点的坐标,进行多项式拟合分别提出各条车道线实例。

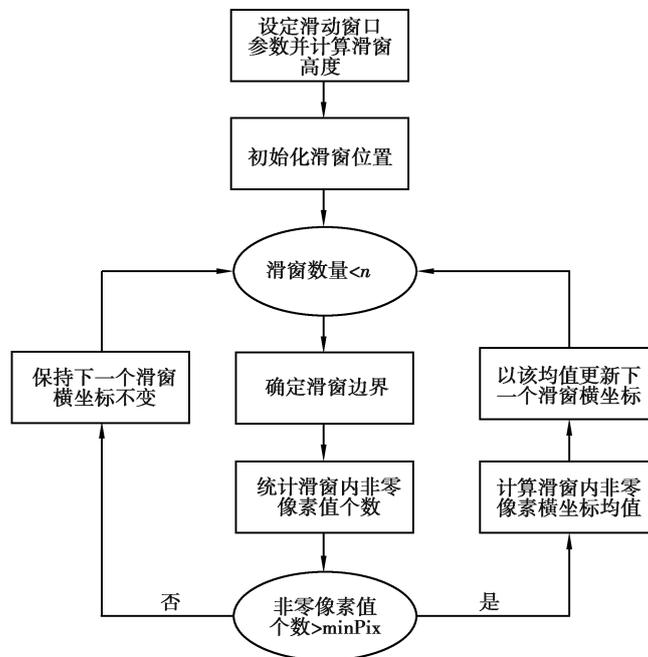


图 4 滑动窗口算法流程图

Fig. 4 Flow chart of sliding window algorithm

3 实验

3.1 实验数据

训练数据包括来源于 2015 CCF 大赛的航拍数据和笔者自采的湖北某地航拍数据,共 256 幅。前者共标注了 5 类物体,分别是背景(标记为 0)、植被(标记为 1)、道路(标记为 2)、建筑(标记为 3)、水体(标记为 4),这里对该数据标签进行修改,仅分为道路和非道路两类。所有数据的尺寸被统一调整为 512×512 ,构成整个数据集,并按照 7:2:1 的比例划分训练数据、验证数据和测试数据。

3.2 U-Net 模型训练及道路区域识别

选用二元交叉熵损失函数(binary cross entropy, BCE),将批大小(Batchsize)设置为 4,将初始学习率设为 0.001,采用 Polynomial 学习率下降方法和 Adam 优化算法,并设置迭代次数(Epoch)为 100,通过最小化二元交叉熵损失函数训练 U-Net 网络,损失函数值的下降过程如图 5 所示。尽管 U-Net 网络在较小的数据集上就能表现出强大的分割性能,但是作为深度学习网络,网络的性能极大地依赖于训练数据集。因此,在训练时通过随机翻转、旋转、截取、模糊,以及随机变换亮度、对比度、饱和度、色调等手段对数据集增强。使用训练好的网络模型对航拍影像进行语义分割。

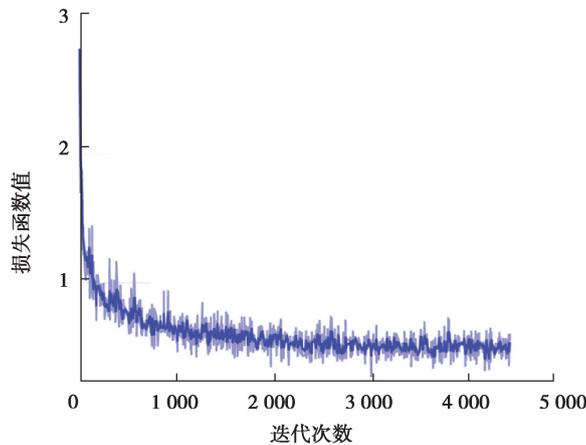


图 5 损失函数下降过程

Fig. 5 Loss function diagram

道路区域识别本质是图像语义分割,可以使用混淆矩阵来定量的评价分割的精度,因此采用准确率 P 、召回率 R 以及交并比 IoU 作为基础的评价指标。这些评价指标定义如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}},$$

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

$$IoU = \frac{N_{TP}}{N_{TP} + N_{FN} + N_{FP}},$$

式中: N_{TP} 表示被正确分割为道路区域像素点的个数, N_{FP} 表示非道路区域像素但被分割为道路区域的像素个数, N_{FN} 表示道路区域像素但被分割为非道路区域的像素个数,分割结果见表 1 和图 6。

表 1 U-Net 网络道路区域识别评价

Table 1 Evaluation of road area recognition based on U-Net

准确率	召回率	交并比
0.921 8	0.930 2	0.899 8

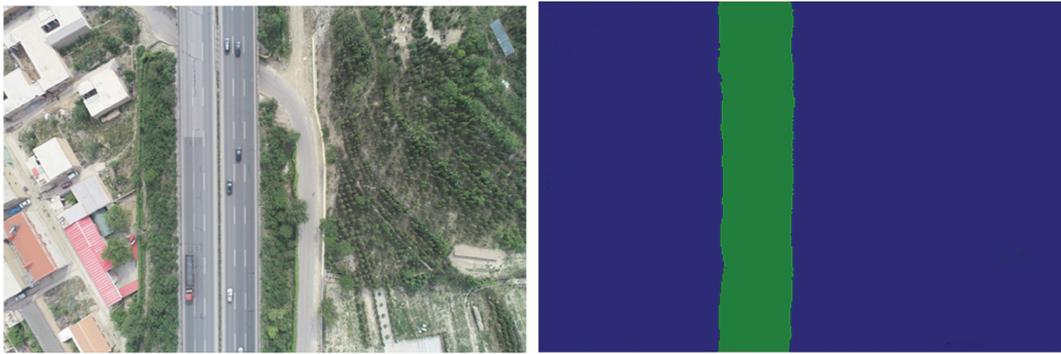


图 6 道路区域识别效果

Fig. 6 Result of road area recognition

3.3 车道线特征提取

通过颜色空间变换将原始航拍影像变换为 HSL 颜色空间, HSL 即色相、饱和度、亮度, 该颜色空间使用一个圆锥空间模型来描述, 可以很好地反映色调、亮度和饱和度的变化, 并且可以更好地定义和描述一种颜色, 十分适合处理饱和度变化明显的图像。如图 7 所示在道路区域中, 黄色和白色的车道线相对于路面颜色饱和度差异明显, 因此选用 HSL 中的 S 通道提取车道线的颜色特征。

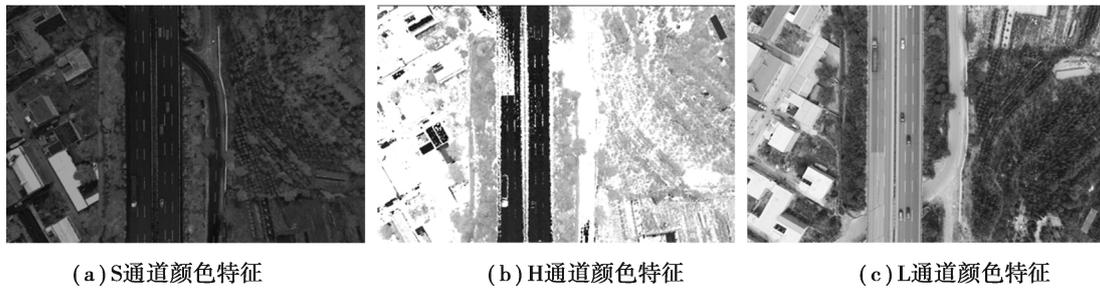


图 7 HSL 颜色空间各通道颜色特征

Fig. 7 Color characteristics of each channel in color space HSL

车道线的结构性特征使得车道线边缘梯度突变往往发生在某一特定方向, 求取该方向的梯度能够有效提取出车道边缘特征, 也避免了引入其他方向的边缘噪声。该方向可以通过统计梯度方向的众数获得, 对图像施加该角度的旋转变换, 使得车道线与图像横向边缘垂直, 计算变换之后的横向梯度间接获得车道线在该方向上的梯度边缘特征, 如图 8 所示。



图 8 车道线梯度特征

Fig. 8 Gradient characteristics of lane

对上述特征分别进行 ROI 掩膜处理过滤非道路区域噪音, 并使用 Otsu 算法进行阈值分割获得二值化的车道线颜色和梯度, 联合车道线颜色梯度特征, 并使用形态学滤波的方法对特征图进行处理, 消除二值图

像中的小目标(如毛刺和孤立点),填充凹陷弥合孔洞和裂缝,获得如图 9 所示的二值化后的车道线特征。

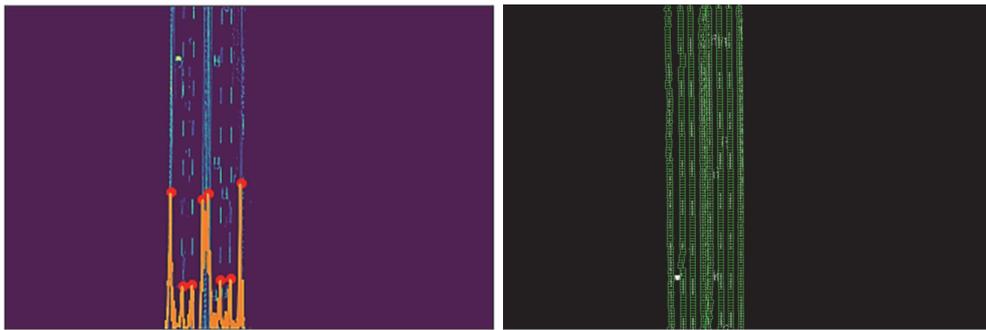


图 9 Otsu 算法二值化的车道线特征

Fig. 9 Binary lane feature by Otsu

3.4 车道线检测

滑动窗口算法需要确定车道线的起始位置以及车道线的数目,将表示车道线颜色和梯度特征的二值图像按一定角度旋转变换,使得车道线垂直于特征图的横向边缘,统计特征图每列非零像素个数绘制特征直方图(图 10(a)),根据车道线之间像素距离确定特征直方图的局部最大值,以此确定车道线的数目和车道线在图像中的初始位置,并使用滑动窗口算法准确地检测车道线像素,如图 10(b)所示,并采用多项式拟合滑窗内的非零像素,拟合结果如图 11 所示。



(a) 车道线特征直方图

(b) 滑动窗口检测车道线

图 10 车道线特征直方图及滑动窗口检测车道线

Fig. 10 Histogram of lane line and result of sliding window algorithm



图 11 车道线检测拟合效果图

Fig. 11 Result of lane line detection

目前评估车道线检测的方法主要通过统计检测到的车道线条数与真实车道线条数的比例来计算准确率和召回率。准确率为检测到的车道线中真实车道线的比例,召回率为检测正确的车道线占全部真实车道线的比例。据文献[22],针对车载摄像头影像,Hough 变换检测方法的准确率和召回率为 63.47%和 59.04%,LaneNet 的准确率和召回率为 92.81%和 93.19%。在检测效率方面,按照摄像头平均成像帧率 30 fps,车辆

行驶速度 60 km/h 换算, Hough 变换检测方法的检测效率为 4.6 m/s, LaneNet 方法的检测效率为 10.4 m/s。

在实验中, 根据无人机俯视影像的特点, 将车道线的宽度定义为 10 个像素建立车道线缓冲区, 检测的车道线与实际车道线的缓冲区有重叠则认为检测正确, 以检测到的车道线长度与真实车道线完全重合的长度比例来计算准确率和召回率。参照上文公式(4), 其中 TP 表示被正确识别的车道线长度, FP 表示错误识别为车道线的长度, FN 表示真实车道线中未被识别的长度。经实验计算精确率为 79.01%, 召回率为 83.12%。而在检测效率方面, 单幅影像检测的道路长度达到了百米以上, 检测效率为 25.2 m/s。因此如表 2 所示, 相比其他方法, 本方法具有明显的效率优势。

同时, 本检测方法在单次检测结果的基础上, 还可以经过质量检查调整滑窗和拟合参数, 进行二次修正, 最终能够达到 100% 拟合实际车道线的效果。

表 2 实验结果对比

Table 2 Comparison of experimental results

	基于地面 KITTI 数据集		基于无人机影像的
	Hough 变换检测方法	LaneNet 方法	本文方法
精确率/%	63.47	92.81	79.01
召回率/%	59.04	93.19	83.12
检测效率/(m·s ⁻¹)	4.6	10.4	25.2

4 结论与讨论

选用无人机影像作为数据源, 充分利用无人机影像空间分辨率高、成像范围广和无须透视变换的优点。针对无人机影像的特点, 避开了采用单一深度学习直接检测车道线的方法, 而是提出了新的深度学习和图像视觉特征相结合的车道线提取方案: 使用 U-Net 网络对航拍影像分割获取道路区域, 计算道路区域内车道线的梯度和颜色特征, 并使用 Otsu 算法进行阈值分割, 借助特征直方图使用滑动窗口和多项式拟合检测拟合车道线。通过实验测试, 本方法在保证一定精度前提下, 实现了远高于地面影像的检测效率, 在一定程度上可以帮助高精度地图低成本、高效、灵活地获取与更新车道线信息。未来将进一步针对路面标线模糊、阴影遮挡、路面车辆等问题进行优化研究。

参考文献:

- [1] 刘经南, 吴杭彬, 郭迟, 等. 高精度道路导航地图的进展与思考[J]. 中国工程科学, 2018, 20(2): 99-105.
Liu J N, Wu H B, Guo C, et al. Progress and consideration of high precision road navigation map[J]. Strategic Study of CAE, 2018, 20(2): 99-105. (in Chinese)
- [2] 梁宗正, 童杨. 高精度地图国内外发展现状及对策[J]. 科技中国, 2021(1): 13-16.
Liang Z Z, Tong Y. The development status and countermeasures of high precision maps in China and abroad[J]. China Scitechnology Think Tank, 2021(1): 13-16. (in Chinese)
- [3] 尹彤, 黄鹤, 郭迟, 等. 面向自动驾驶的高精地图生产技术及数据模型标准化探讨[J]. 中国标准化, 2021(4): 33-37.
Yin T, Huang H, Guo C, et al. Discussion on high-definition map production technology and data model standardization for autonomous driving[J]. China Standardization, 2021(4): 33-37. (in Chinese)
- [4] Narote S P, Bhujbal P N, Narote A S, et al. A review of recent advances in lane detection and departure warning system[J]. Pattern Recognition, 2018, 73: 216-234.
- [5] Xing Y, Lv C, Chen L, et al. Advances in vision-based lane detection: algorithms, integration, assessment, and perspectives on ACP-based parallel vision[J]. IEEE/CAA Journal of Automatica Sinica, 2018, 5(3): 645-661.
- [6] Ozgunalp U. Robust lane-detection algorithm based on improved symmetrical local threshold for feature extraction and inverse perspective mapping[J]. IET Image Processing, 2019, 13(6): 975-982.
- [7] 周宏宇, 宋旭, 刘国英. Haar 特征耦合级联分类器的车道线检测算法[J]. 计算机工程与设计, 2020, 41(6): 1719-1724.
Zhou H Y, Song X, Liu G Y. Lane detection algorithm based on Haar feature based coupled cascade classifier[J]. Computer Engineering and Design, 2020, 41(6): 1719-1724. (in Chinese)

- [8] 易世春, 李克强, 郭君斌, 等. 基于边缘分布及特征聚类的车道标记线检测[J]. 汽车工程, 2014, 36(10): 1210-1215, 1179.
Yi S C, Li K Q, Guo J B, et al. Lane marking detection based on edge distribution and feature clustering[J]. *Automotive Engineering*, 2014, 36(10): 1210-1215, 1179. (in Chinese)
- [9] Lee D H, Liu J L. End-to-end deep learning of lane detection and path prediction for real-time autonomous driving[EB/OL]. (2021-02-09)[2021-03-01]. <https://arxiv.org/abs/2102.04738>.
- [10] Hou Y N, Ma Z, Liu C X, et al. Learning lightweight lane detection CNNs by self attention distillation[EB/OL]. (2019-08-02)[2021-03-01]. <https://arxiv.org/abs/1908.00821>.
- [11] Huval B, Wang T, Tandon S, et al. An empirical evaluation of deep learning on highway driving[EB/OL]. (2015-04-17)[2021-03-01]. <https://arxiv.org/abs/1504.01716v3>.
- [12] 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. IEEE, 2018: 286-291.
- [13] 王卓, 闫浩文, 禄小敏, 等. 一种改进 U-Net 的高分辨率遥感影像道路提取方法[J]. 遥感技术与应用, 2020, 35(4): 741-748.
Wang Z, Yan H W, Lu X M, et al. High-resolution remote sensing image road extraction method for improving U-net[J]. *Remote Sensing Technology and Application*, 2020, 35(4): 741-748. (in Chinese)
- [14] 张永宏, 严斌, 田伟, 等. 基于 PPMU-net 的多特征高分辨率遥感道路提取[J/OL]. 计算机工程与应用: 1-9(2021-04-07). <http://kns.cnki.net/kcms/detail/11.2127.TP.20200401.1001.002.html>.
Zhang Y H, Yan B, Tian W, et al. Multi-feature high-resolution remote sensing road extraction based on PPMU-net[J/OL]. *Computer Engineering and Applications*: 1-9 (2021-04-07). <http://kns.cnki.net/kcms/detail/11.2127.TP.20200401.1001.002.html>. (in Chinese)
- [15] 郭正胜, 李参海, 王智敏. U 型卷积神经网络的 ZY-3 影像道路提取方法[J]. 测绘科学, 2020, 45(4): 51-57.
Guo Z S, Li C H, Wang Z M. Road extraction from ZY-3 remote sensing image based on U-Net like convolution architecture[J]. *Science of Surveying and Mapping*, 2020, 45(4): 51-57. (in Chinese)
- [16] 金飞, 王龙飞, 刘智, 等. 一种双 U-Net 的遥感影像道路提取方法[J]. 测绘科学技术学报, 2019, 36(4): 377-381, 387.
Jin F, Wang L F, Liu Z, et al. Double U-net remote sensing image road extraction method[J]. *Journal of Geomatics Science and Technology*, 2019, 36(4): 377-381, 387. (in Chinese)
- [17] Azimi S M, Fischer P, Körner M, et al. Aerial LaneNet: lane-marking semantic segmentation in aerial imagery using wavelet-enhanced cost-sensitive symmetric fully convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(5): 2920-2938.
- [18] Jin H, Feng Y M. Automated road pavement marking detection from high resolution aerial images based on multi-resolution image analysis and anisotropic Gaussian filtering[C]//2010 2nd International Conference on Signal Processing Systems, July 5-7, 2010, Dalian, China. IEEE, 2010: V1-337-V1-341.
- [19] 王秋生, 贺云涛, 张晓辉, 等. 基于无人机航拍图像的车道线检测方法综述[J]. 无人系统技术, 2019, 2(5): 9-16.
Wang Q S, He Y T, Zhang X H, et al. Review of lane detection methods based on UAV aerial images[J]. *Unmanned Systems Technology*, 2019, 2(5): 9-16. (in Chinese)
- [20] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C/OL]//Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015, 2015: 9351:234-241. doi:10.1007/978-3-319-24574-4_28. https://link.springer.com/chapter/10.1007%2F978-3-319-24574-4_28#citeas.
- [21] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 道路交通标志和标线 第 3 部分: 道路交通标线 GB 5768.3—2009[S]. 北京: 中国标准出版社, 2009.
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Road traffic signs and markings - Part 3: road traffic markings GB 5768.3—2009[S]. Beijing: Standards Press of China, 2009. (in Chinese)
- [22] 罗胜, 赵丽, 王慕抽. 基于道路特征信息的车道结构化解析[J]. 北京航空航天大学学报, 2020, 46(9): 1643-1649.
Luo S, Zhao L, Wang M C. Lane semantic analysis based on road feature information[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2020, 46(9): 1643-1649. (in Chinese)