

基于 YOLOv8 的自动驾驶车道检测改进算法

阮庭海, 樊卫华

(南京理工大学 自动化学院, 南京 210094)

摘要: 针对自动驾驶领域的车道自动检测中存在的检测准确率低、实际应用难等问题, 研究基于 YOLO 与传统图像处理算法混合的车道检测算法; 基于车载传感器拍摄的视频, 利用 YOLOv8 算法检测并标记车前/侧方附近的物体, 并将图像视角转换到鸟瞰视角, 利用基于滑动窗口的二次多项式法识别当前帧的车道线, 融合前序帧的车道信息, 检测出当前帧的车道; 经过数据集和实际场景的测试表明, 算法的检测准确性提升 10% 以上, 检测速度明显提升。

关键词: YOLO; 曲线车道检测; 滑动窗口; 自动驾驶; 计算机视觉

Improved Curve Lane Detection Algorithm for Autonomous Vehicles Based on YOLOv8

RUAN Tinghai, FAN Weihua

(School of Automation, Nanjing University of Science & Technology, Nanjing 210094, China)

Abstract: Aiming at the problems of low detection accuracy and difficult practical application in automatic lane detection in the field of automatic driving, a mixed lane detection algorithm based on YOLO and traditional image processing algorithms is studied. Based on the video captured by the on-board sensors, YOLOv8 algorithm is used to detect and mark the objects near the front or side of the vehicle, and the image viewpoint is converted to a bird's-eye view, and the quadratic polynomial method based on sliding window is used to identify the lane lines with current frame, and fuse the lane information of previous frames to detect the lane in the current frame. Tests on datasets and actual scenarios show that the algorithm improves the detection accuracy by more than 10% and significantly increases the detection speed.

Keywords: YOLO; curve lane detection; sliding window; autonomous driving; computer vision

0 引言

随着汽车工业、人工智能技术和电子技术的飞速发展, 车辆的辅助驾驶和自动驾驶技术受到了人们的广泛关注, 已成为模式识别、人工智能等领域的研究热点之一^[1]。车道的检测与识别是自动驾驶的核心关键技术之一^[2], 是汽车能判断是否偏移车道、调整行车方向和速度、避免与前侧方车辆等物体发生碰撞、安全行驶的前提。

车道的检测主要是利用图像处理或人工智能技术, 从车载传感器, 如相机、激光雷达等感知的信息中将车道线检测出来。目前, 车道检测的研究主要有两个方向: 基于传统图像处理的检测算法和基于深度学习模型的检测算法。

1) 基于传统图像处理的检测算法:

基于传统图像处理的检测算法是利用车道的几何等特征的匹配, 如曲率、颜色^[3]和纹理^[4], 来检测车道。这类算法的步骤为: 图像预处理; 边缘检测; 确定直线并选择最优直线^[5-8]。研究重点在车道特征的提取与匹配。

车道特征的提取利用车道边缘的检测。文献 [9] 使用 Canny 边缘检测算法进行车道检测; 文献 [7] 和 [8] 分别将可操纵滤波器和 Gabor 滤波器应用于车道边缘检测。

特征提取后的步骤是车道匹配。车道的基本类型包括: 直线和曲线。直线车道检测较为成熟的算法是霍夫变换。曲线车道检测的准确率取决于曲率的确定^[3], 比较典型的方法是用二次函数和圆形方程^[10]来对曲率建

收稿日期: 2023-12-04; 修回日期: 2024-01-11。

基金项目: 江苏省科技重大专项 (BG2024041)。

作者简介: 阮庭海 (1994-), 男, 硕士。

樊卫华 (1975-), 男, 博士, 副教授。

引用格式: 阮庭海, 樊卫华. 基于 YOLOv8 的自动驾驶车道检测改进算法[J]. 计算机测量与控制, 2025, 33(2): 31-36.

模。近年来,也开始使用 KNN、SVM^[11] 或 DBScan^[12] 等机器学习算法,对车道曲率进行建模。

2) 基于深度学习模型的检测算法:

近年来,深度学习算法发展迅速,在车道检测领域也得到了广泛的应用。文献 [13] 提出了一种基于 SegNet (Semantic Segmentation Network) 构建的 LaneNet 的网络,该网具有两个解码器,分别用于检测二进制掩模中的车道和分割道路。文献 [8] 使用全卷积神经网络 (FCN, fully convolutional network) 与全连接层作为原始解码器,用帽形核来推断车道边缘,并应用随机抽样一致性 (RANSAC, random sample and consensus) 来改善结果,该模型表现出较强的性能。文献 [7] 提出了一种混合深度架构,将卷积神经网络 (CNN, convolutional neural networks) 与循环神经网络 (RNN, recurrent neural networks) 结合在一起,利用连续行驶场景的多帧图像来进行车道检测。

基于深度学习模型的检测算法准确率较高,但计算量较大,对硬件算力要求较高,在车载平台上的部署和推广难度较大。

对于自动驾驶而言,车道检测的同时,也需要进行对车辆前侧方的目标(如:车、人、物等)进行检测,以确保驾驶的安全性。深度学习算法,如:R-CNN^[14]、Fast R-CNN^[15]、Faster R-CNN^[16]、SSD^[17] 和 YOLO^[18-21] 在其中得到了广泛的应用。Faster R-CNN 和 Mask R-CNN 准确性高,但计算复杂度高,计算时间较长。YOLO 和 SSD 等网络的计算速度得到了显著的提升,但结果的可靠性相对较低。

针对自动驾驶中的车道检测算法,为提高检测的准确性,降低计算量和对硬件的依赖,本文研究了一种基于 YOLO 与传统图像处理算法混合的车道检测算法,通过识别车辆周边的车辆,降低干扰的影响,然后利用传统的算法对车道进行检测。

1 基于 YOLOv8 的车道检测改进算法

1.1 检测算法流程

本文提出的车道检测算法如图 1 所示,包括 3 个阶段。1) 预处理,包括相机校准、畸变校正、车辆检测与感兴趣区域 (ROI, region of interest) 确认; 2) 车道检测,包括组合滤波、过滤车辆、获取鸟瞰图及基于二次多项式的车道线拟合; 3) 基于先前帧的结果进行比较和筛选,详细流程如图 2 所示,下面详细介绍各阶段的方法。

1.2 图像预处理

1.2.1 相机校准和图像校正

图像畸变存在于所有相机拍摄的图像和视频中,可能导致物体大小、形状或位置改变,影响图像处理结果

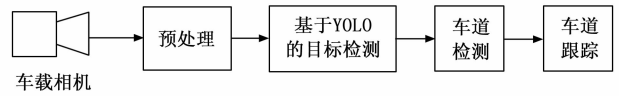


图 1 算法的框架




图 2 车道检测流程图

的准确性。为了纠正畸变,需要计算相机校准矩阵和畸变系数。

计算相机校准矩阵,相机的外部参数和内部参数。对于世界坐标系中的任一点 (X_w, Y_w, Z_w) 与其在图像坐标系中的投影 (u, v) , 存在如下关系:

$$\begin{bmatrix} u' \\ v' \\ z' \end{bmatrix} = P \begin{bmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{bmatrix} \quad (1)$$

$$u = \frac{u'}{w'} \quad (2)$$

$$v = \frac{v'}{w'}$$

其中: $P = K \times [R | t] \in \mathbb{R}^{3 \times 4}$ 为投影矩阵, $K =$

$$\begin{bmatrix} f_x & \gamma & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}$$

为 x 和 y 的焦距,图像的光学中心坐标,轴之间的倾斜,通常为 0; $[R | t]$ 为外参数矩阵,其中 $R \in \mathbb{R}^{3 \times 3}$ 为旋转矩阵, $t \in \mathbb{R}^{3 \times 1}$ 为平移向量。

校准的目标是用已知的点 (X_w, Y_w, Z_w) 和它们对应的图像坐标 (u, v) 来找到矩阵 K , R 和 t 。一般用同一相机拍摄的多张棋盘格来计算相机的校准矩阵和畸变系数。

设畸变点的坐标为 $(x_{\text{distorted}}, y_{\text{distorted}})$, 则该点的实际坐标与畸变坐标之间的关系如式 (3) 所示:

$$\begin{aligned}x_{\text{distorted}} &= x(1 + k_1 \times r^2 + k_2 \times r^4 + k_3 \times r^6) \\y_{\text{distorted}} &= y(1 + k_1 \times r^2 + k_2 \times r^4 + k_3 \times r^6) \quad (3)\end{aligned}$$

其中： k_1, k_2, k_3 为镜头的径向畸变系数， $r^2 = x^2 + y^2$ 。

利用获得的畸变系数，就可以对图像进行校正，图 3 是一个路面图像校正前后的对比，在图像的右侧可以观察到校正的效果。




图 3 畸变去除前后的结果

1.2.2 ROI 的确定

由车载相机捕获的图像通常尺寸较大，包含了大量的与车道检测无关的信息，为降低计算量，提高检测算法的准确性和实时性，本文定义了一个 ROI，该区域为视频图像的 1/3 范围，如图 4 所示。



图 4 图像 ROI 的确定

1.3 车道检测

1.3.1 组合滤波

为了增强算法的识别率，本文使用一种阈值、颜色空间和梯度的组合滤波算法，提升图像的质量。算法的主要过程如下：

首先，使用 Sobel 算法进行边缘检测。Sobel 运算使用如式 (4) 所示的 3×3 的卷积核来检测 X 和 Y 方向上的梯度变化。

$$\begin{aligned}\mathbf{G}_x &= \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * I \\ \mathbf{G}_y &= \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * I \quad (4)\end{aligned}$$

其中： $*$ 表示卷积运算符， I 表示输入图像。梯度幅值 G 为：

$$G = \sqrt{G_x^2 + G_y^2} \quad (5)$$

然后，将梯度图像转换成二值图像。二值化阈值采用 Otsu 法^[28]自动确定阈值。经过上述处理后的结果如图 5 所示。




图 5 边缘检测处理的结果

从图 5 (c) 得知，仅使用 Sobel 算法难以准确检测车道。为此，引入颜色特征，以提高检测的准确率。

常用的彩色图像色彩空间，包括：RGB、HSV 和色相饱和度亮度 (HSL)。与 RGB 颜色空间相比，HSL 颜色空间的每个独立颜色通道都可以单独使用，更适合于捕捉图像特征领域。为此，本文将 RGB 颜色空间转换为 HSL，然后用 Otsu 法获得阈值。HSL 三个通道的检测效果如图 6 所示，本文选择使用效果最好的 S 通道进行车道检测。




图 6 基于 HSL 的二值化边缘图像

为进一步提升检测的准确率，本文融合了两个滤波器，结果如图 7 所示。

1.3.2 过滤车辆

在高密度交通场景下，前侧方车辆常遮挡车道，形成干扰，过滤车辆显然可减少干扰，提高检测的准确率。

本文利用 YOLOv8 识别并标记出干扰车辆，将它们从 ROI 中移除，然后再检测车道线。应用 YOLOv8




图 7 组合滤波结果

之前,对模型进行了预处理,数据集基于 COCO 数据集进行,主要集中于车辆、行人、自行车等常见的目标物识别。利用训练好的模型,对图像 ROI 区域的车辆进行过滤,然后进行车道检测,效果如图 8 所示,效果得到明显提升。




图 8 车道检测效果对比

1.3.3 生成鸟瞰图

车载相机因视角原因,图像存在透视效应,即实际平行的车道线,因透视而在远处汇聚。而鸟瞰视图可以消除这种透视效应的影响,更容易地检测车道线。为此,本文对图像进行透视变换,得到鸟瞰图,如图 9 所示。




图 9 透视变换后鸟瞰视图

1.3.4 拟合车道线

透视变换后,车道线还存在断续等现象,直接检测难以获得满意的效果,本文利用基于滑动窗口的卷积运算,对窗口内像素值进行累加,找出该窗口内像素重叠最高的位置,即最有可能是车道标志的位置,结果如图 10 所示。

在上述处理的基础上,通过已知的车道线坐标 (x, y) ,利用最优二次曲线方程和用 Moore-Penrose 逆方法来确定最优解,进而确定车道上其他的点。




图 10 拟合对比结果

1.4 车道跟踪

由于车道并不总是直线,还可能受到路面文字等干扰的影响,因此对车道进行跟踪,预测一段时间内路线方向变化,以提高检测的准确率。

考虑右侧和右侧车道线的曲率通常没有显著差异,且弯曲方向相同,因此采用如图 11 所示的连续帧处理算法。




图 11 车道线跟踪算法流程

该算法的主要思想为:若无法检测到线方程时,则将上一帧图像中车道线的曲率应用于当前帧;若能成功检测到线方程时,将当前帧的曲率与前 5 帧平均曲率值对比,无显著差异认为结果可信,并作为新的曲率值。

应用上述算法的结果如图 12 所示,显然算法可以提升车道检测的成功率和准确率。



图 12 应用算法前后的结果

2 实验结果与分析

为验证本文方法的有效性,在不同场景中进行算法

测试,同时与其他检测算法进行比较。算法测试的数据有两类:数据集的视频及实际行车过程中录制的视频。

两者分别截取部分典型路况,包括:桥梁、上下坡等,并使用软件将视频分割成小片段。根据视频片段内路况的复杂程度,将测试结果分成简单路况和复杂路况。

2.1 简单路况测试

如图 13 所示,在正常的光照条件下,算法能够以较高的准确度检测车道,并进行标注。即便光照有变化,车道检测的准确度仍可以保持在较高的范围。



图 13 简单路况下检测效果

2.2 复杂路况测试

如图 14 所示,在复杂的道路条件下,车道的检测率有所下降,对高度弯曲的道路、陡峭的上坡道,车道检测出现了部分偏离现象。



图 14 复杂路况的检测效果

2.3 对比测试

选取了两组测试视频,第 1 组为正常路况,没有复杂的车道结构,道路噪音较少。第 2 组为复杂路况,有通过桥梁时的阴影、道路状况差、噪音水平高以及不断变化的车道结构。

本文算法与已有算法的比较结果如表 1 和表 2 所示,部分检测效果如图 15 和 16 所示,可见本文算法的平均准确度均有明显提高。

表 1 第一组测试结果比较

算法	平均准确度/%
HOG + Kalman	57.80
HSL + Sobel filter	83.12
本文算法	96.81

表 2 第二组测试结果比较

算法	平均准确度/%
HOG + Kalman	30.13
HSL + Sobel filter	43.43
本文算法	67.14



图 15 数据集 1 测试部分结果



图 16 数据集 2 部分结果

3 结束语

本文提出了一种基于 YOLOv8 的自动驾驶车道检测改进算法,引入了一种结合了梯度阈值和 S 通道阈值的组合滤波边缘检测方法,利用 YOLOv8 预训练模型去除车前侧方干扰车辆信息,通过二次曲线方程对车道进行了拟合和跟踪。测试表明本文的算法可以有效提高正常路况和复杂路况车道检测的准确度,具有实际应用价值。

当然本文算法仍有不足和局限性,今后将改进滤波器和车道曲率拟合的算法,进一步提高算法在复杂路况下的车道检测准确率,同时优化算法,降低对硬件的依赖性。

参考文献:

[1] 陈虹,郭露露,宫洵,等. 智能时代的汽车控制[J]. 自动化学报, 2020, 46 (7): 1313 - 1332.

[2] 李骏扬,金立左,费树岷,等. 基于多尺度特征表示的城市道路检测[J]. 电子与信息学报, 2014, 36 (11): 2578 - 2585.

[3] CHEN Y, WU D H. Multi-sensor based lane detection and object tracking method [C] //2007 Chinese Control Conference, Zhangjiajie, China, 2007: 137 - 140.

[4] YENIKAYA S, YENIKAYA G, DVEN E. Keeping the vehicle on the road; a survey on on-road lane detection sys-

- tems [J]. *ACM Computing Surveys*, 2013, 46 (2): 1 – 43.
- [5] AMOL B, MONSON H, MARK T S. Polar randomized hough transform for lane detection using loose constraints of parallel lines [C] // *International Conference on Acoustics, Speech and Signal Processing*, Prague, Czech Republic, 2011: 1037 – 1040.
- [6] MOHANMED A. Real time detection of lane markers in urban streets [C] // *IEEE Intelligent Vehicles Symposium*, Eindhoven, Netherlands, 2008: 7 – 12.
- [7] JOEL C M, MOHAN M T. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2006, 7 (1): 20 – 37.
- [8] ZHOU S Y, JIANG Y H, XI J Q, et al. A novel lane detection based on geometrical model and gabor filter [C] // *IEEE Intelligent Vehicles Symposium*, La Jolla, CA, USA, 2010: 59 – 64.
- [9] RONG W B, LI Z J, ZHANG W, et al. An improved canny edge detection algorithm [C] // *2014 IEEE International Conference on Mechatronics and Automation*, Tianjin, China, 2014: 577 – 582.
- [10] BYAMBAA D, SABIR H, DEOK J L. Highly curved lane detection algorithms based on Kalman filter [J]. *Appl. Sci.*, 2020, 10 (7): 2372.
- [11] NARAYANA M, BHACANI N P G. A lane detection system to assistant drivers for better driving using gradient decent algorithm comparison with KNN and SVM [C] // *2022 International Conference on Business Analytics for Technology and Security (ICBATS)*, Dubai, United Arab Emirates, 2022: 1 – 6.
- [12] WANG J T, HONG W, GONG L. Lane detection algorithm based on density clustering and RANSAC [C] // *2018 Chinese Control And Decision Conference (CCDC)*, Shenyang, China, 2018: 919 – 924.
- [13] WANG Z, REN W Q, QIU Q. LaneNet: real-time lane detection networks for autonomous driving [J]. *Computer Vision and Pattern Recognition*, 2108: 1 – 9.
- [14] ROSS G, JEFF D, TREVOR D, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // *2014 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, USA, 2014: 580 – 587.
- [15] ROSS G. Fast R-CNN [C] // *IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 2015: 1440 – 1448.
- [16] REN S Q, HE K M, ROSS G, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39 (6): 1137 – 1149.
- [17] LIU W, DRAGOMIR A, DUNMITRU E, et al. SSD: single shot multibox detector [C] // *European Conference on Computer Vision*, 2015: 1 – 10.
- [18] JOSEPH R, SANROSH D, ROSS G, et al. You only look once: unified, real-time object detection [C] // *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 2016: 779 – 788.
- [19] JOSEPH R, ALI F. YOLOv3: an incremental improvement [J]. *Arxiv E-Prints*, 2018. Doi:10.48550/arXiv.1804.02767.
- [20] ALEXEY B, WANG CY, LIAO HYM. YOLOv4: optimal speed and accuracy of object detection [J]. *Arxiv E-Prints*, 2020. doi: 10.48550/arXiv.2004.10934.
- [21] DILLON R, JORDAN K, HONG J, et al. Real-time flying object detection with YOLOv8 [J]. *ARXIV E-PRINTS*, 2023. Doi:10.48550/arxiv.2305.09972.
- [22] BANGARE S, DUBAL A, BANGARE P, et al. Reviewing Otsu's method for image thresholding [J]. *International Journal of Applied Engineering Research*, 2015, 10: 21777 – 21783.
- (上接第 8 页)
- [17] 余浩帅, 汤宝平, 张 楷, 等. 小样本下混合自注意力原型网络的风电齿轮箱故障诊断方法 [J]. *中国机械工程*, 2021, 32 (20): 2475 – 2481.
- [18] 汪祖民, 聂晓宇, 王颖洁, 等. 基于小样本的胶囊网络轴承故障诊断方法 [J]. *计算机工程与设计*, 2023, 44 (4): 1259 – 1266.
- [19] ZHANG A, LI S, CUI Y, et al. Limited data rolling bearing fault diagnosis with few-shot learning [J]. *IEEE Access*, 2019, 7: 110895 – 110904.
- [20] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样本滚动轴承故障诊断研究 [J]. *仪器仪表学报*, 2022, 43 (10): 241 – 251.
- [21] ZUOYI C, YUANHANG W, JUN W, et al. Wide residual relation network-based intelligent fault diagnosis of rotating machines with small samples [J]. *Sensors*, 2022, 22 (11): 4161 – 4175.
- [22] YUFENG Q, XIANJUN S. Fault diagnosis method for rolling bearings based on two-channel CNN under unbalanced datasets [J]. *Applied Sciences*, 2022, 12 (17): 8474 – 8491.
- [23] 赵晓平, 彭 澎, 张永宏, 等. 改进孪生网络在小样本轴承故障诊断中的应用 [J]. *计算机工程与应用*, 2023, 59 (19): 294 – 304.