自动驾驶汽车的车道跟踪：利用 TensorFlow 进行跨定位和传感器融合的图像处理深度学习

Al-amin Abdullahi*, Mohammed Nazeh

波茨坦欧洲应用技术大学 德国

【摘要】车道追踪是自动驾驶汽车的关键组成部分，使其能够安全高效地在道路上行驶。本文探讨了强大的深度学习框架 TensorFlow 在图像处理中的车道追踪应用，重点介绍了其在定位和传感器融合方面的应用。自动驾驶汽车依靠大量传感器感知周围环境并做出明智的决策。其中，基于视觉的系统发挥着关键作用，因为它们能够提供有关道路环境的实时信息。深度学习技术，尤其是卷积神经网络 (CNN)，已被证明在处理视觉数据方面非常有效。TensorFlow 是一个流行的开源机器学习库，已成为实现此类网络的强大工具。本文探讨了如何利用 TensorFlow 进行车道追踪。本文深入探讨了用于检测和追踪车载摄像头拍摄图像中车道标记的 CNN 模型的开发。此外，本文还探讨了车道追踪与自动驾驶的两个关键环节——定位和传感器融合——的集成。准确的车道追踪对于车辆定位至关重要，因为它能够提供关键的位置信息。基于 TensorFlow 的模型可以通过持续更新车辆相对于检测到的车道的位置来提高定位精度。此外，传感器融合对于整合来自激光雷达、雷达和摄像头等各种传感器的信息至关重要。TensorFlow 有助于将车道跟踪数据与来自其他传感器的信息融合，从而增强汽车全面感知环境并做出安全驾驶决策的能力。

【关键词】图像处理；定位；传感器融合

【收稿日期】2025 年 6 月 3 日 【出刊日期】2025 年 7 月 10 日 【DOI】10.12208/j.ipcv.20250002

Lane tracking in self-driving cars: leveraging TensorFlow for deep learning in image processing across localization, and sensor fusion

Al-amin Abdullahi, Mohammed Nazeh*

University of Europe for Applied Sciences, Potsdam, Germany

【**Abstract**】Lane tracking is a critical component of self-driving cars, enabling them to navigate roads safely and efficiently. This article discusses the utilization of TensorFlow, a powerful deep learning framework, in the context of image processing for lane tracking, focusing on its application in localization and sensor fusion. Self-driving cars rely on a multitude of sensors to perceive their surroundings and make informed decisions. Among these, vision-based systems play a pivotal role, as they provide real-time information about the road environment. Deep learning techniques, particularly convolutional neural networks (CNNs), have proven to be highly effective in processing visual data. TensorFlow, a popular open-source machine learning library, has emerged as a robust tool for implementing such networks. This article explores how TensorFlow can be leveraged for lane tracking. It delves into the development of CNN models tailored to detect and track lane markings in images captured by onboard cameras. Furthermore, the integration of lane tracking into two key aspects of autonomous driving: localization and sensor fusion. Accurate lane tracking is crucial for vehicle localization, as it provides critical positional information. TensorFlow-based models can contribute to improved localization accuracy by continuously updating the vehicle's position relative to the detected lanes. Additionally, sensor fusion is essential for consolidating information from diverse sensors like LiDAR, radar, and cameras. TensorFlow facilitates the fusion of lane tracking data with

*通讯作者：Al-amin Abdullahi

注：本文于 2023 年发表在 Advances in Computer and Communications 期刊 4 卷 5 期，为其授权翻译版本。

information from other sensors, enhancing the car's ability to perceive its environment comprehensively and make safe driving decisions.

【**Keywords**】Image processing; Localisation; Sensor fusion

1 简介

近年来，自动驾驶技术的发展和人们的关注度不断提升，并取得了显著进展。自动驾驶汽车的发展引起了汽车行业和科技爱好者的广泛关注。这种日益增长的兴趣源于自动驾驶汽车的诸多潜在优势，包括增强安全性、改善交通流量以及为行动不便人士提供更多便利。

车道检测在配备高级驾驶辅助系统 (ADAS) 的现代车辆和自动驾驶汽车的运行中起着至关重要的作用，它提供车道保持辅助、偏离警告和居中等功能。目前主要有两种车道检测方法：经典计算机视觉和深度学习。经典计算机视觉方法需要在特征工程、道路建模和具体情况处理方面投入大量工作，这使得它在应对各种驾驶情况、环境和可能出现的意外障碍时缺乏韧性。相比之下，深度学习方法近年来在克服这些挑战方面取得了重大进展。

此外，路径预测（即跟随车道行驶的能力）对于 ADAS 和自动驾驶汽车而言都是一项关键任务，因为它支持主动驾驶辅助以及横向和纵向运动的控制。这项任务取决于多种因素，包括车辆的速度和转向角度、道路几何形状以及同一车道上是否存在其他车辆。此外，它还涉及车辆自身感知、传感和控制系统的集成[1]。

端到端自动驾驶由深度神经网络驱动，通过处理原始传感器数据（例如摄像头图像和激光雷达点云）并生成控制命令，代表了自动驾驶汽车开发领域的范式转变。尽管它摒弃了模块化的任务划分，但它本质上包含两个共生的方面：环境感知和驾驶策略。前者采用卷积神经网络(CNN)从输入图像中提取复杂信息，最终形成低维特征表示。这反过来又为驾驶策略模块（通常表现为全连接网络）提供信息，该模块负责协调控制命令的生成。虽然大量文献依赖这些命令作为唯一的引导信号，但单独使用这些命令可能会导致潜在表示不理想，从而引发过拟合、泛化能力受限以及分布偏移等挑战。因此，寻求更丰富的驾驶场景潜在表示变得至关重要。为了实现这一目标，必须借鉴人类驾驶的经验，其中立体视觉提供深度信息，而多模态感知则丰富了对环境的理解。多模态传感器融合技术对于整合视觉和深度数据以实现卓越的端到端自动驾驶至关重要，通过将摄像头图像与深度洞察融合，不断证明其在提高驾驶性能方面的价值，最终确保更安全、更可靠的自动驾驶汽车[2]。

人工智能的进步推动了智能驾驶技术的显著进步，智能汽车对于安全高效的交通运输至关重要。车道检测是智能驾驶的一个关键研究领域，用于高级驾驶辅助系统(ADAS)中的车道偏离预警以及 GPS 受限环境下的自动驾驶汽车导航等功能。目前的方法涉及线段提取，通常采用霍夫变换和 LSD 等技术，但这些技术可能会产生误报，需要额外的后处理。几何约束通常用于分类，但它们难以识别某些线段，例如来自围栏的线段。此外，已经提出了端到端神经网络用于车道检测，但将人类知识融入这些网络具有挑战性，并且需要大量带标签的图像数据集，这在实际应用中存在局限性[3]。

美国汽车工程师协会(SAE)是工程师的专业协会，它将驾驶辅助技术进步分为六个不同的级别。在 0 级，这些属性提供建议和临时援助，例如提供盲点警告或应用紧急制动。1 级和 2 级为驾驶员提供转向和/或制动/速度控制。从 3 级及更高级别开始，当使用这些技术功能时，驾驶员不会主动参与。3 级自动驾驶系统要求驾驶员在需要时接管控制。4 级系统可以在有限的条件下自动驾驶车辆，例如在高速公路上，无需驾驶员干预。最后，5 级系统可以在所有情况下完全自动驾驶。更高级别的自动驾驶技术依靠先进的环境感知能力来检测周围的车辆和潜在危险。

车道检测对自动驾驶汽车构成了重大挑战，多年来一直是计算机视觉领域的焦点。本质上，车道检测涉及识别多种特征，这对于计算机视觉和人工智能方法来说是一个复杂的问题。在过去的几十年里，车辆集成了各种自动驾驶功能，包括单目视觉和基于摄像头的视觉系统的视听模式。在自适应巡航控制(ACC)等应用中，单目摄像头在标准焦距下，在相关距离的前视场景中展现出了令人印象深刻的精度[4]。

本报告旨在探讨车道追踪对于自动驾驶汽车的重要性，并深入探讨 TensorFlow 在图像处理任务中扮演的角色，而这些任务对于自动驾驶系统的成功至关重要。通过了解车道追踪的底层技术及其应用，我们可以深入了解自动驾驶领域的挑战和机遇，并为这一激动人心的领域的进一步发展铺平道路。

2 通过图像处理进行车道跟踪

本文提出的车道跟踪方法论围绕计算机视觉技术与深度学习方法的集成构建。本节概述了实现自动驾驶汽车精确实时车道检测与跟踪所采用方法的关键组成部分。

3 车道追踪系统

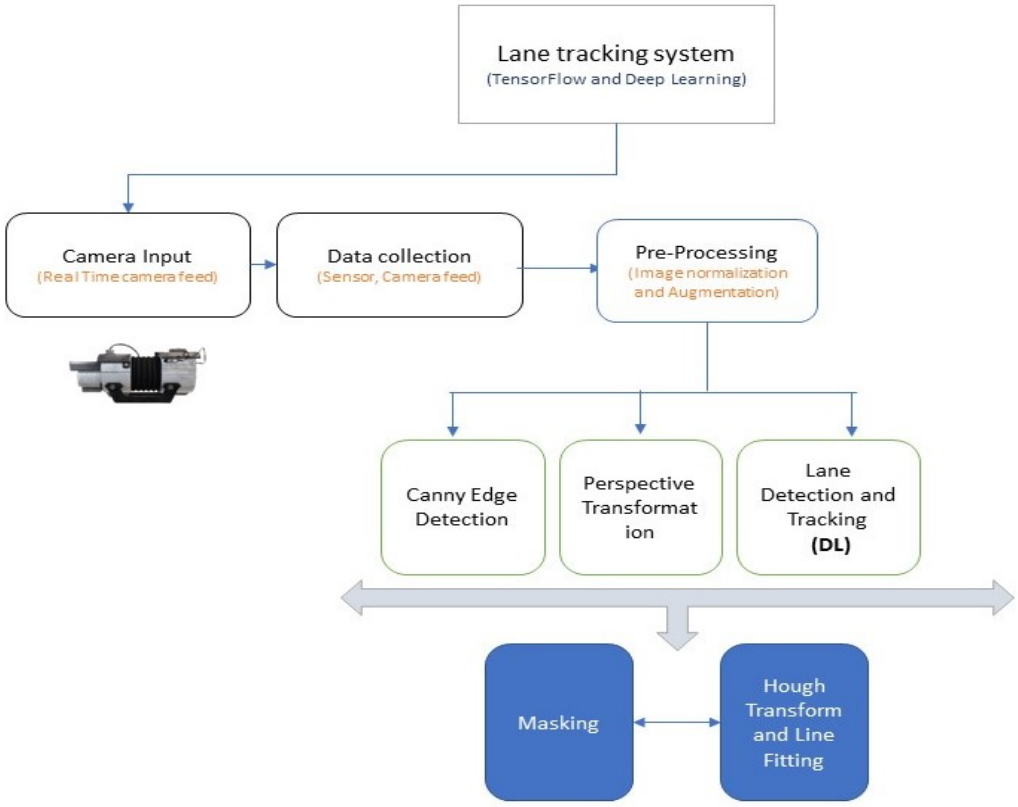

图 1　基于图像处理的基本车道跟踪流程

使用 TensorFlow 进行自动驾驶汽车车道追踪的过程包含几个关键步骤：数据收集，即收集图像或视频并手动标记；预处理数据；使用卷积神经网络进行模型开发；在标记数据集上训练模型；使用准确度和精确度等指标评估其性能；最后，将训练好的模型部署到车辆中进行实时车道追踪，辅助自动驾驶系统的决策和控制操作。使用透视变换和车道区域分析进行地平线定位提供了代码片段，演示如何使用 TensorFlow 进行自动驾驶汽车的车道追踪。

3.1 使用透视变换进行地平线定位

提供的脚本中执行透视变换的代码部分重点关注的是本地化的这一关键方面。该过程可以分解为以下步骤：

定义兴趣点：第一步是在原始图像中定义四个源点（源点）。这些点代表道路上的兴趣区域(ROI)。在给定场景中，这些点经过策略性选择，形成一个梯形，将摄像头视野范围内的道路车道全部覆盖。

定义目标点：接下来，定义四个目标点（Destinationpoints）。这些点指定了变换后图像的期望形状，即车道线平行的矩形。选择这些点是为了实现场景的俯视图，从而更容易确定车辆相对于道路的位置。

计算透视变换矩阵：使用 cv2.getPerspectiveTransform() 函数计算透视变换矩阵(M)。该矩阵将源点映射到目标点，从而将 ROI 转换为所需的自上而下的视图。

图 2　图像处理逐步进行透视变换

应用透视变换：最后，使用 cv2.warpPerspective() 将变换应用于原始图像。此过程生成“扭曲”图像，该图像代表道路及其周围物体的鸟瞰图。

代码中的透视变换部分是自动驾驶汽车定位的基础步骤。通过将摄像头视图转换为自上而下的表示，汽车可以获得有关其位置和周围环境的关键信息，这对于安全可靠的自主导航至关重要。这一变换过程是提升汽车对道路的理解能力并在驾驶过程中做出明智决策的宝贵工具。

3.2 车道区域分析

给出的代码似乎是使用 OpenCV 检测图像中车道线的分步过程。以下是每个部分的细分：

在初始阶段，我们首先显示原始图像，利用 OpenCV 库（`cv2`）读取图像文件“test_image.jpg”，然后通过`cv2.imshow()`进行呈现，之后继续下一步。之后，我们无缝过渡到将图像转换为灰度图像，使用`cv2.cvtColor()`和`cv2.COLOR_RGB2GRAY`参数并显示结果，再次等待用户输入。接下来的步骤是通过高斯模糊平滑灰度图像，并按原样显示，然后暂停以进行用户交互。最后，我们进行 Canny 边缘检测，将其应用于模糊图像以显示关键边缘。与前几个阶段一样，结果通过`cv2.imshow()`呈现，我们等待用户输入后再继续下一步。

进入下一阶段，我们引入了遮罩感兴趣区域的

图 3　从第一张图像到 Canny Edge 的图像处理工作流程概述

概念。这需要定义两个函数“canny_edge()”和“reg_of_interest()”，前者复制 Canny 边缘检测过程，后者描绘特定的感兴趣区域。然后将该区域遮罩应用于 Canny 边缘图像，并通过“cv2.imshow()”显示结果，并提示用户进行交互。第六阶段进一步完善了“canny_edge()”和“reg_of_interest()”函数，现在集成了“cv2.bitwise_and()”以增强遮罩应用。遮罩后的图像再次显示，等待用户输入以继续操作。在第七阶段，霍夫变换占据了中心位置，引入了新函数“show_lines()”，用于在图像上绘制线条。代码利用霍夫变换（“cv2.HoughLinesP()”）检测遮罩图像中的线条，并通过“show_lines()”将它们精细地渲染到空白画布上。使用`cv2.imshow()`展示结果图像，该图像包含检测到的线条，中间会暂停一段时间以便用户交互。最后，第 8 阶段将所有元素和谐地组合成一个完美的收尾阶段。我们重新读取原始图像，创建副本，对该副本应用 Canny 边缘检测和感兴趣区域蒙版，并利用霍夫变换检测和修饰车道线。最终的图像（现在包含车道线）通过`cv2.imshow()`显示，我们耐心等待用户交互，然后结束本次图像处理之旅。这些阶段为图像处理爱好者提供了清晰的学习路径，涵盖了分析和增强图像的基本技术。

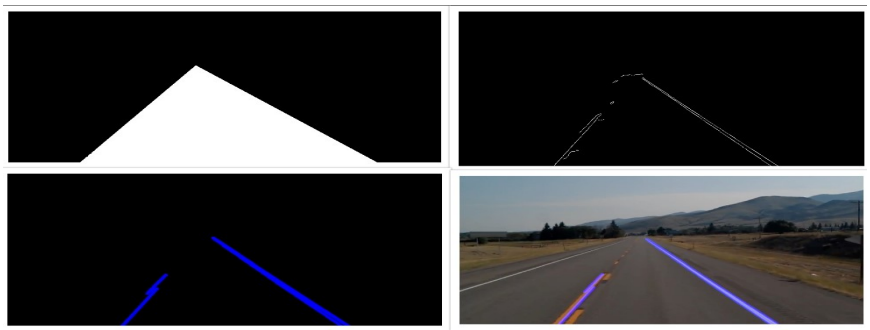

图 4　从感兴趣区域到应用霍夫变换的图像处理工作流程

4 实验分析与讨论

本文探讨了强大的深度学习框架 TensorFlow 在车道追踪图像处理领域的应用。我们的重点扩展至其与自动驾驶系统的两个基本组成部分——定位和传感器融合的集成。本讨论将深入探讨这些发现的意义及其更广泛的影响。

TensorFlow 提供了一个强大的平台，可用于实现车道追踪的深度学习模型。其灵活性和丰富的工具库简化了 CNN 的开发和部署。这些网络在处理视觉数据方面表现出色，非常适合自动驾驶汽车所需的实时图像分析。将 TensorFlow 集成到车道追踪过程中，使车辆能够持续更新其相对于检测到的车道的位置，从而提高定位精度。

4.1 地平线定位和车道区域分析

本文详细介绍了车道跟踪的关键技术，例如通过透视变换和车道区域分析实现的地平线定位。将摄像头视图转换为自上而下的视图，为车辆提供安全导航所需的关键信息。从鸟瞰视角理解道路环境的能力增强了决策过程，有助于自动驾驶汽车的安全运行。车道区域分析（包括灰度转换、高斯模糊、Canny 边缘检测和区域遮罩）为准确实时的车道检测奠定了基础。

使用 TensorFlow 实现的车道追踪功能无缝集成到更广泛的自动驾驶领域。车道追踪系统的数据收集、模型开发、训练和实时部署是自动驾驶系统决策和控制操作的重要组成部分。这种集成凸显了其在自动驾驶汽车中的实用性和广泛应用潜力[5]。

4.2 实时车道跟踪系统的优化策略：总结与建议

为了优化车道追踪系统，提出了几种策略。高效的图像处理技术（例如边缘检测、颜色分割和特征提取）可以增强实时性能。使用 GPU、FPGA 或 DSP 的硬件加速可以减轻密集型图像处理任务的负担。特征缩减技术专注于可能包含车道的相关区域，从而降低计算复杂度。并行化将任务划分为更小的子任务，以有效利用多个处理单元。模型优化技术（例如剪枝、量化和专用架构）可以改善实时推理。与摄像头、激光雷达或雷达等多个传感器的融合可以提高准确性和鲁棒性。系统级优化、基准测试和分析也有助于提高整体性能。总体而言，优化车道追踪系统需要仔细考虑各种策略、超参数和神经网络架构，以实现实时性能，同时满足特定的要求和约束。

我们对使用 TensorFlow 进行车道追踪的探索，揭示了深度学习在自动驾驶领域的变革潜力。TensorFlow 助力开发精准实时的车道追踪系统，从而提升自动驾驶汽车的安全性和效率。随着我们不断完善这些系统并应对挑战，我们将为自动驾驶汽车的广泛应用及其诸多优势的实现铺平道路。

这些发现不仅推动了自动驾驶技术的发展，也凸显了 TensorFlow 作为这一激动人心且快速发展的领域中基于深度学习的解决方案的关键推动者所发挥的作用。进一步的研究与合作对于推动自动驾驶技术的持续进步和创新至关重要。

5 结论

总而言之，本文强调了车道追踪在自动驾驶汽车中的重要性，并重点介绍了基于 TensorFlow 的图像处理技术在定位和传感器融合方面的作用。利用 TensorFlow，可以开发出强大的车道检测和追踪算法，使自动驾驶汽车能够安全导航并根据周围环境做出明智的决策。本文讨论的优化策略为提升车道追踪系统的实时性能、准确性和鲁棒性提供了宝贵的见解。然而，诸如检测附近车辆和预测车道变换等挑战仍然存在，需要进一步改进检测和预测算法，并提高强大的决策能力。克服这些挑战对于成

功实施自动驾驶系统并实现其在道路安全和效率方面的潜在优势至关重要。

参考文献

[1] Lee, D.-H., & Liu, J.-L. (2021, December 9). End-to-End Deep Learning of Lane Detection and Path Prediction for Real-Time Autonomous Driving.

[2] Huang, Z., Lv, C., Xing, Y., & Wu, J. (2020, August 1). Multi-modal Sensor Fusion-Based Deep Neural Network for End-to-end Autonomous Driving with Scene Understanding.

[3] Sun, Y., Li, J., & Sun, Z. (2019). Multi-Stage Hough Space Calculation for Lane Markings Detection via IMU and Vision Fusion. National University of Defense Technology, Changsha, China. Published: 19 May 2019.

[4] Kachhoria, R., Jaiswal, S., Lokhande, M., & Rodge, J. (2023). Lane Detection and Path Prediction in Autonomous Vehicles Using Deep Learning. In Intelligent Edge Computing for Cyber Physical Applications (Intelligent Data-Centric Systems, Chapter 7, pp. 111-127).

[5] Senthamilarasu, S., & Ranjan, S. (2020). Applied Deep Learning and Computer Vision for Self-Driving Cars. Publication Date: August 14, 2020.

版权声明：©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。
https://creativecommons.org/licenses/by/4.0/

OPEN ACCESS