

基于多传感器数据融合的无人驾驶车辆 临时道路实时感知系统研究

王立勇 崔 傲 苏清华 王浩东 宋 越

(北京信息科技大学机电工程学院 北京 100192)

摘 要: 在交通事故或道路管控等紧急情况下,常用交通锥指示临时道路。然而,当前自动驾驶研究主要聚焦结构化道路,而针对非结构化道路的相关研究则较少。因此,确保无人驾驶车辆在临时道路环境中能够准确感知交通锥构建的临时道路对提升行驶安全性具有重要意义。提出了一种基于多传感器数据融合的深度神经网络模型,通过快速检测特殊场景下的交通锥信息,实现临时道路检测。该框架通过改进型的 YOLOX 模型通过机器视觉获取环境中交通锥的颜色信息,并将其与激光雷达检测的交通锥距离数据进行融合,进而实现临时道路的实时感知。实验结果表明,该模型在非结构化道路环境中单帧检测耗时 31 ms,在 15 m 内检测准确率超过 85%,可实现交通锥的实时检测,达到设计目标,对提升无人驾驶车辆行驶安全有重要意义。

关键词: 临时道路检测;机器视觉;激光雷达;数据融合;深度学习

中图分类号: TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Real-time perception systems for temporary roads in unmanned vehicles using multi-sensor data fusion

Wang Liyong Cui Ao Su Qinghua Wang Haodong Song Yue

(College of Mechatronic Engineering, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: Traffic cones are commonly used to mark temporary roads in emergencies like traffic accidents or road control. However, current autonomous driving research focuses mainly on structured roads, with relatively little on unstructured roads. Thus, enabling unmanned vehicles to accurately perceive temporary roads formed by traffic cones in such environments is vital for improving driving safety. This study proposes a deep learning model based on multi-sensor data fusion to detect temporary roads by quickly identifying traffic cones in special scenarios. The framework uses an improved YOLOX model to obtain traffic cones color information via machine vision, then fuses this with the distance data of traffic cones detected by LiDAR to achieve real-time perception of temporary roads. Experimental results show that in unstructured road environments, the model has a 31 ms single-frame detection time and over 85% accuracy within 15 meters. It enables real-time traffic cone detection, meets design goals, and is of great significance for enhancing the driving safety of unmanned vehicles.

Keywords: temporary road detection; machine vision; LiDAR; sensor data fusion; deep learning

0 引 言

高级驾驶辅助系统(advanced driver-assistance systems, ADAS)可在车辆行驶过程中,通过车载传感器检测周围环境,在结构化与非结构化道路环境中准确识别合适的可行驶区域,预判潜在危险并提升行驶安全性^[1]。以往研究中,自动驾驶领域的多数成果均在结构化道路环境下取得,如街道^[2]、高速公路等^[3],而针对非结构化道路(如临时道路)

的研究则较少。临时道路通常在交通管控或事故现场设置,通过交通锥标识道路两侧边界,因此,在临时道路场景下,无人驾驶车辆对交通锥的检测成功率将显著影响其行驶安全性^[4]。

交通锥感知过程包括识别与定位两部分。识别过程依赖于机器视觉系统^[5]或激光雷达数据,传统方法基于图像处理或聚类分析^[6],但近年来基于深度学习的目标检测器逐渐成为主流。其中,YOLO 系列模型因其高速度和精度

平衡而广泛应用,例如YOLOv5^[7]、YOLOv7^[8]和YOLOv8^[9]等版本通过优化网络结构和损失函数不断提升性能,但这些模型在嵌入式系统中部署时存在如何平衡实时性与预测精度的挑战。尽管标准YOLOv7或YOLOv8模型预测精度高,但在嵌入式系统有限的硬件资源中无法保证预测实时性,而YOLOv7-Tiny^[10]和YOLOv8-Nano^[11]等轻量级变体已降低计算开销,但会大幅降低预测精度。

相比之下,YOLOX^[12]作为一款无锚点模型,通过简化检测头和改进特征融合机制,在速度和精度之间取得较好平衡。但原始YOLOX模型在复杂非结构化环境中对小目标(如远距离交通锥)的检测能力有限。因此,本研究提出改进的YOLOX-Bit网络,通过引入高效通道注意力(efficient channel attention, ECA)模块增强特征聚焦能力,采用焦点损失(focal loss, FL)解决正负样本不平衡问题,并集成循环门控卷积(recurrent gated convolutions, HorBlock)以扩大感受野和捕捉全局上下文。这种设计权衡依据在于:针对临时道路场景中交通锥检测的实时性优先需求,优先保障部署效率,同时通过多传感器融合补偿精度损失。

定位过程用于感知交通锥与无人驾驶车辆之间的距离,进而可划分非结构化道路中的可行驶区域。该距离可通过机器视觉或激光雷达两种方式检测:其中,基于相机的视觉测量方法能达到非常高的精确度^[13],但其距离预测精度较低^[14];尽管激光雷达获取的点云包含精度高、稳定性好的距离信息,但受误检测目标的影响,且缺乏交通锥的颜色与纹理信息,无法直接用于可行驶区域标记^[15]。因此,结合两种传感器的特性,通过数据融合技术可提升交通锥识别与定位的准确性^[16]。

由于机器视觉系统与激光雷达属于两类具有不同工作原理与频率的传感器,数据融合过程在时间同步与空间标定方面面临挑战^[17]。时间同步通常通过最新时间戳的数据帧进行近似匹配实现^[18],而空间标定则通过计算单应性矩阵(homography matrix, H)建立两类传感器之间的空间关联关系^[19]。其中,空间标定过程会产生误差,且上述时间同步方法将不同时间点的数据视为等效数据,导致在时间间隔内引入不稳定性。因此,当前融合方法在将三维数据投影到二维空间时,常出现对准偏差,需采用阈值法进行后处理;但现有方法无法适配多变的应用环境,易产生匹配错误或匹配缺失问题。

为此,本研究提出一种基于深度学习和多传感器融合的模型解决上述问题。在临时道路场景中,通过机器视觉系统与32线激光雷达分别实现交通锥检测。该框架主要包含3部分:

1)基于改进的YOLOX网络,从道路图像中识别交通锥,并输出交通锥边界框(bounding boxes, bbox)与颜色类别。

2)采用欧氏聚类算法,在点云中检测交通锥并输出其

三维位置。

3)通过融合算法计算已处理的相机数据与激光雷达数据之间的匹配关系。

1 交通锥检测方法

1.1 基于机器视觉系统的交通锥识别

无人驾驶车辆行驶过程中,使用相机采集临时道路的RGB图像。图像预处理第一步为缩放与填充(保持宽高比),随后输入改进的YOLOX-Bit网络进行交通锥检测;最终,检测到的交通锥将在对应的bbox内输出。

跨阶段部分连(cross-stage-partial-connections, CSP): CSP模块的主要功能是增强信息流并降低计算量。本研究采用两种形式的CSP模块,即CSP_T_X与CSP_F_X,分别如图1(a)和(b)所示。其中,T和F分别表示模块是否包含残差连接(residual connection)。包含残差连接的CSP_T_X模块设置在骨干网络前端,以避免梯度消失问题。X代表卷积块的数量。




图1 CSP模块的结构

Fig. 1 The structure of CSP block

YOLOX是一款高性能无锚点YOLO模型。为在嵌入式计算机上实现实时检测,本研究设计改进的YOLOX-Bit网络,对其网络结构进行优化。该网络由骨干网络、颈部网络与头部网络3部分组成,如图2所示。为提升网络性能,本研究引入ECA模块与HorBlock。

ECA: ECA是一种简洁高效的通道注意力模块,其结构如图3所示。该模块采用一维卷积实现跨通道交互,同时避免维度衰减。在交通锥检测任务中,ECA模块可帮助网络聚焦有效特征,降低噪声干扰的影响。

HorBlock: 采用Transformer的核心组件构建循环门控卷积网络。通过融入人类自注意力机制的高阶交互,该模块可有效提升模型的表达能力。因此,本研究采用该模块替换图1中原YOLOX模型的部分CSP模块。与原始CSP模块相比,HorBlock能够同时捕捉全局信息与丰富的上下文信息,且作为解码器时可带来更优的密集预测性能,其结构如图4所示。

FL通过抑制负样本与易分类样本对损失值的贡献,提升目标检测器的性能,相关计算公式如式(1)~(3)所示。




图 2 改进的 YOLOX-Bit 网络结构

Fig. 2 The structure of improved YOLOX-Bit network




图 3 ECA 结构

Fig. 3 The structure of ECA




图 4 HorBlock 结构

Fig. 4 The structure of HorBlock

$$FocalLoss(p_t) = -\alpha_t(1 - p_t)^{\gamma} \log(p_t) \quad (1)$$

$$p_t = \begin{cases} p, & y = 1 \\ 1 - p, & y = 0 \end{cases} \quad (2)$$

$$\alpha_t = \begin{cases} \alpha, & y = 1 \\ 1 - \alpha, & y = 0 \end{cases} \quad (3)$$

其中, $FocalLoss$ 表示损失值; 变量 p 代表样本为正样本的预测概率; y 用于指示样本类别 ($y = 1$ 表示正样本, $y = 0$ 表示负样本); 权重因子用于平衡正、负样本的重要性, 而该参数则用于区分易分类与难分类样本。

1.2 基于激光雷达的交通锥距离检测

激光雷达用于高精度感知交通锥距离。预处理与聚类实现检测。

预处理阶段主要完成 3 项任务: 感兴趣区域 (region of interest, ROI) 提取、地面拟合与去除、点云旋转, 如图 5 所示。




图 5 预处理阶段

Fig. 5 Preprocessing step

ROI 提取: 激光雷达生成的原始点云包含车辆周围 360° 的环境信息, 但仅车辆正前方的点云对路径规划具有实际价值。因此, 先提取 ROI 降低计算量, 再进行滤波, 仅保留 X 、 Y 、 Z 坐标分别处于 $(0, 0, 20, 0)$ 、 $(-10, 0, 10, 0)$ 和

$(-h, 0.5-h)$ 范围内的点云,其中, X 轴指向车辆坐标系的车头方向, Y 轴指向车辆左侧, Z 轴垂直于地面, h 为激光雷达安装高度。地面拟合与去除使用地面平面方程,如式(4)所示。

$$ax + by + cz + d = 0 \quad (4)$$

其中, $\mathbf{P}(a, b, c)$ 为拟合平面的法向量, d 为激光雷达安装高度。通过随机抽样一致性(random sample consensus, RANSAC)算法可求解参数 a, b, c, d 并获取地面点云,该算法以图5中的 I_1 (已提取感兴趣区域的点云)为输入拟合地

$$\mathbf{R} = \begin{bmatrix} \cos\theta + \omega_x^2(1 - \cos\theta) & \omega_x\omega_y(1 - \cos\theta) - \omega_z\sin\theta & \omega_y\sin\theta + \omega_x\omega_z(1 - \cos\theta) \\ \omega_x\sin\theta + \omega_x\omega_z(1 - \cos\theta) & \cos\theta + \omega_y^2(1 - \cos\theta) & -\omega_x\sin\theta + \omega_y\omega_z(1 - \cos\theta) \\ -\omega_y\sin\theta + \omega_x\omega_z(1 - \cos\theta) & \omega_x\sin\theta + \omega_y\omega_z(1 - \cos\theta) & \cos\theta + \omega_z^2(1 - \cos\theta) \end{bmatrix} \quad (7)$$

由于变换向量 $\mathbf{T}$ 为 $(0, 0, d)$ 的逆向量,因此可通过式(8)得到转换矩阵 $\mathbf{M}$ 。

$$\mathbf{M} = \begin{pmatrix} \mathbf{R} & \mathbf{T} \\ 0 & 1 \end{pmatrix} \quad (8)$$

聚类阶段旨在得到呈三角形轮廓的交通锥聚类簇。

2 融合检测方法

2.1 多传感器数据校准

机器视觉系统与激光雷达的实时数据相互独立,且数据采集频率不同。本研究中,相机工作频率为15 Hz,激光雷达工作频率为10 Hz,因此,需要进行数据时间同步。

将相机与激光雷达的数据流分别定义为 Q_c 与 Q_l (分别对应彩色图像数据与点云数据),并采用循环队列 O 存储12组 Q_c 与 Q_l 的配对数据。当接收到 Q_l 中的新点云数据 S_l 时,会从 Q_c 中选取与 S_l 时间差最小的彩色图像数据 S_c ,组成数据帧 (S_c, S_l) 。为确保数据帧的有效性,设定一个关键的时间同步阈值 K :仅当 S_c 与 S_l 之间的时间差小于 K 时,该数据帧才被判定为有效并加入循环队列 O 。阈值 K 的选取至关重要,其目的在于权衡同步精度与系统鲁棒性; K 值需足够小,以确保在时间差内由车辆运动导致的目标位移可忽略不计,从而满足后续融合算法对数据瞬时一致性的要求,同时又需具备一定的容错性,避免因传感器时序抖动或频率差异导致大量有效数据被丢弃。若 S_c 与 S_l 的时间差小于阈值 K ,则将该数据帧加入循环队列 O 。每组配对数据帧在后续流程中仅使用一次,使用后即被清除。

此外,相机与激光雷达的坐标系也存在差异,因此需进行空间同步以统一两类坐标系。首先,通过棋盘格标定获取相机内参;随后,将三维空间中的点云数据投影至像素坐标系,完成空间同步。假设三维激光雷达坐标系中的某点 (X_w, Y_w, Z_w) 对应相机像素坐标系中的点 (X_p, Y_p) ,二者关系如式(9)所示。其中, f_x 与 f_y 为相机焦距; c_x 与 c_y 为主点坐标,可通过相机标定获取; 3×3 矩阵 $\mathbf{R}$ 表示旋转, 3×1 向量 $\mathbf{T}$ 表示平移。

面平面。基于式(4)中的参数可计算得到转换矩阵 $\mathbf{M}$,该矩阵用于将点云 I_2 旋转一定角度,得到点云 I_3 。其中,旋转角 θ 为拟合平面法向量 $\mathbf{P}$ 与水平面法向量 $\mathbf{Q}$ 之间的夹角,如式(5)所示;旋转轴 $\omega(\omega_x, \omega_y, \omega_z)$ 如式(6)所示。

$$\theta = \cos^{-1}\left(\frac{\mathbf{PQ}}{\|\mathbf{P}\| \|\mathbf{Q}\|}\right) \quad (5)$$

$$\omega = \mathbf{P} \times \mathbf{Q} \quad (6)$$

根据罗德里格斯旋转公式,可通过式(7)计算得到旋转矩阵 $\mathbf{R}$ 。

$$\begin{pmatrix} x_p \\ y_p \\ 1 \end{pmatrix} = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} R_{11} & R_{21} & R_{31} \\ R_{12} & R_{22} & R_{32} \\ R_{13} & R_{23} & R_{33} \end{pmatrix} \begin{pmatrix} T_1 \\ T_2 \\ T_3 \end{pmatrix} \begin{pmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{pmatrix} = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix} (\mathbf{R}_{3 \times 3} \mathbf{T}_{3 \times 3}) \begin{pmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{pmatrix} \quad (9)$$

2.2 数据融合

激光雷达可提供高精度距离信息,而机器视觉系统则能捕捉目标的颜色与形状特征,因此,融合两类传感器的数据即可实现对交通锥的识别与感知。为降低系统硬件成本,本研究采用软件算法实现数据融合。

库恩-蒙克雷算法常用于计算带权二分图中的最优匹配。受该算法启发,本研究设计一种数据融合算法,通过确定两种传感器模态检测结果之间的匹配关系实现融合。该算法以边界框集合 B 和点云聚类集合 C 为输入,输出边界框与点云聚类间的匹配关系集合 $V = \{u_i, v_j, \dots\}$ 。具体流程为:首先初始化邻接矩阵 $\mathbf{M}$,矩阵第 i 行、第 j 列的元素为权重 W_{ij} ;接着遍历集合 B 中每个边界框,计算其质心 u_i ;再遍历集合 C 中每个点云聚类,计算其质心并将该质心投影至像素坐标系,得到 v_j ,随后通过式(10)计算 W_{ij} :

$$W_{ij} = \alpha \times \text{Euclidean}(u_i, v_j) + \beta \quad (10)$$

其中, α, β 为常数, α 作为欧氏距离项的缩放因子,用于调节视觉检测框质心 u_i 与点云聚类投影质心 v_j 之间距离对权重 W_{ij} 的影响程度; β 作为一个小的偏置常数,其主要作用是避免当欧氏距离极小时权重过于接近零,确保匹配决策的稳定性,并在距离相近时提供一个基础的差异性区分。在本研究中,经过实验验证,系数 α 取1.5,偏置项 β 取0.1。 $\text{Euclidean}(u_i, v_j)$ 为 u_i 与 v_j 的欧氏距离,最后,采用库恩-蒙克雷算法对权重矩阵 $\mathbf{W}_{ij}$ 进行最优匹配求解,得到匹配关系集合 V 。

具体而言,该数据融合算法以欧氏距离总和最小为目

标,将每个交通锥的 bbox 与点云聚类簇进行配对。其中,欧氏距离基于相机像素坐标系下的边界框质心与点云聚类簇质心计算得出。

3 实验与讨论

本节对所提出框架的性能进行评估与分析。

3.1 实验材料与设备

本实验采用松灵 SCOUT 2.0,该车辆采用四轮差速转向方式,配备 4 台直流电机与 1 块 30 Ah 电池,其长、宽、高分别为 0.93、0.70、0.35 m,如图 6(a)所示。

实验选用红、蓝、黄三色交通锥搭建临时道路,交通锥的长、宽、高尺寸为 200 mm×200 mm×300 mm,如图 6(b)所示。




图 6 实验材料与设备
Fig. 6 Experimental materials and devices

实验所用嵌入式计算机为 NVIDIA Jetson AGX Xavier,该设备搭载 8 核 ARM 中央处理器(CPU)、512 核 Volta 架构图形处理器(GPU,含 64 个张量核心)及 16 GB 内存(RAM);车辆控制算法基于机器人操作系统(robot operating system, ROS)开发。交通锥检测系统包含 1 台 Stereolabs ZED2 立体相机与 1 台 RoboSense RS-LiDAR-32 激光雷达。其中,Stereolabs ZED2 配备 2 台彩色相机,水平(H)、垂直(V)、对角(D)视场角分别为 110°×70°×120°,可输出分辨率 1 920×1 080、帧率 15 Hz 的彩色图像;RoboSense RS-LiDAR-32 为 32 线激光雷达,工作帧率为 10 Hz。机器视觉系统(即 Stereolabs ZED2)与激光雷达的安装高度分别为距地面 0.64 与 0.39 m。

3.2 机器视觉系统检测结果分析

用于改进的 YOLOX-Bit 网络训练与验证的数据集包含 10 678 张图像,这些图像拍摄于不同地点及多种光照条件下,其中 4 种不同的实验场景如图 7(a)~(d)所示。数据集按 9:1 比例划分,其中 90% 的图像用于网络训练,10% 用于验证。

采用 COCO 评价指标对检测性能进行评估。平均精度(average precision, AP)会因交并比(intersection over union, IOU)阈值的设置不同而产生差异,其计算范围为 [0.5, 0.95],且在该范围内按 0.05 的步长逐点计算。

所有 AP 值的平均值即为综合平均精度(AP0.5:




图 7 数据集中交通锥示例
Fig. 7 Example traffic cone images in dataset

0.95)。实验结果根据边界框内像素数量划分为 3 类(小目标、中目标、大目标),并分别计算各类别的平均精度,对应记为小目标平均精度(APs)、中目标平均精度(APM)与大目标平均精度(APL)。


采用 NVIDIA GeForce RTX 3090 显卡训练机器学习网络,详细参数设置如表 1 所示。

表 1 训练参数设置
Table 1 Parameters used in training

参数设置	值
训练输入尺寸	(416,416)
学习率	0.005
训练轮次	300
无数据增强轮次	15
权重衰减	0.000 5
动量	0.9
非极大值抑制阈值	0.65
优化器	SGD*

训练过程中损失值(loss)与 AP 的变化趋势如图 8(a)和(b)所示。

本研究还选取其他 YOLO 系列网络(包括 YOLOv5n、YOLOX-Nano、YOLOX-Tiny 及 YOLOv7-Tiny),在相同






图 8 AP0.5:0.95 变化趋势和损失值变化趋势
Fig. 8 The changes of AP0.5:0.95 and loss during training

参数设置与数据集下对其进行训练。所有网络均采用预训练权重开展迁移学习,对比结果如表 2 所示。

表 2 不同 YOLO 网络的精度对比

Table 2 Precision comparison by different YOLO networks

网络模型	AP0.5/ %	AP0.5:0.95/ %	FLOPs/ G	Params/ M
YOLOv5n	91.01	62.24	4.10	1.76
YOLOX-Nano	88.03	58.79	1.08	0.90
YOLOX-Tiny	90.13	63.01	6.44	5.03
YOLOv7-Tiny	95.26	65.17	5.51	6.02
YOLOX-Bit (本研究)	87.96	56.66	0.33	0.28

表 3 消融实验

Table 3 Dissolution test

模型	构建方法	AP0.5/%	AP0.5:0.95/%	APS/%	APM/%	APL/%	FLOPs/G	Params/M
A	Model scaling	85.80	52.90	39.2	70.5	78.0	0.33	0.23
B	A+ECA	53.97	53.97	40.6	71.3	77.6	0.33	0.23
C	A+FL	53.52	53.52	40.1	71.1	77.3	0.33	0.23
D	A+HorBlock	53.69	53.69	40.4	71.4	76.6	0.33	0.28
E	A+ECA+FL	54.40	54.40	41.0	71.6	77.5	0.33	0.23
F	A+ECA+HorBlock	53.31	53.31	39.4	71.3	76.6	0.33	0.28
G	A+FL+HorBlock	54.15	54.15	40.5	71.4	77.5	0.33	0.28
H	A+ECA+FL+HorBlock	54.65	54.65	41.3	71.6	78.5	0.33	0.28

模型,其中模型 D 的 APL 降幅达 1.4%。基准模型的性能受特征提取能力限制,且由于数据集中大尺寸交通锥样本数量较少,注意力机制与 FL 使网络更倾向于学习易训练的中小尺寸目标,最终导致 APL 下降。模型 E 融合 ECA 与 FL,该模型可帮助网络聚焦关键信息,降低噪声及正负样本不平衡带来的影响,因此其 AP0.5:0.95 比基准模型高 1.5%。模型 F 与 G 的结果与模型 E 相近。

模型 H 融合 ECA、FL 与 HorBlock,在 8 个机器学习模型中,除 AP0.5 比模型 D 低 0.2% 外,其余几乎所有指

改进的 YOLOX-Bit 网络参数量不足参数量最多的 YOLOv7-Tiny 的 1/20,且其计算开销在 5 个机器学习网络中也最小,仅为 0.33 G 次浮点运算(GFLOPs)。这表明,在硬件资源严格受限的嵌入式系统中,改进的 YOLOX-Bit 模型比其他 YOLO 系列网络更适合部署。实车测试中,在 TensorRT 库的支持下,该模型部署于 NVIDIA Xavier 嵌入式计算机时,交通锥检测平均耗时为 12.6 ms,可满足车辆实时检测需求。

在综合平均精度 (AP0.5:0.95) 方面,改进的 YOLOX-Bit 模型在所有网络中最低,分别比 YOLOv5n、YOLOX-Nano、YOLOX-Tiny 及 YOLOv7-Tiny 低 5.58%、2.13%、6.35% 和 8.51%;但这 4 个模型的计算开销分别是改进 YOLOX-Bit 模型的 12.5、3.3、19.5 和 16.7 倍。AP0.5(IOU=0.5 时的平均精度)的对比结果与 AP0.5:0.95 趋势一致。因此,尽管新模型的预测精度略有下降,但其计算效率大幅提升,能够满足实时性要求。为验证改进 YOLOX-Bit 网络中新增模块(包括 ECA、FL 及 HorBlock)的性能,在交通锥图像数据集上开展消融实验。本实验未使用预训练权重,结果如表 3 所示。

以基准模型 A 为参照,该模型通过将 YOLOX-Nano 的宽度因子从 0.25 降至 0.125、同时保持深度因子为 0.33 得到。模型 B、C、D 分别用于验证 ECA、权重为(0.7,0.3)的 FL 及 HorBlock 的性能。与基准模型 A 相比,模型 B、C、D 均提升 AP0.5:0.95、小目标平均精度(APS)与中目标平均精度(APM),但大目标平均精度(APL)均低于基准

标均取得最高值。这表明,ECA、FL 与 HorBlock 的组合可帮助网络充分利用特征,并在此基础上通过扩大感受野提升 APL。此外,模型 H 的计算负载与模型 D、F、G 一致。综上,模型 H 是适用于交通锥检测的最优机器学习网络。

3.3 激光雷达检测结果分析

激光雷达获取的点云数据通过点云库(point cloud library, PCL)进行处理,预处理结果如图 9 所示。图 9(a)中的原始点云包含车辆周围 360°的环境信息,但仅车辆正

前方的点云包含交通锥数据,通过对其进行感兴趣区域的提取,得到图 9(b),最后对感兴趣区域的点云行进再次提取,分别得到地面附近的点云与针对交通锥的点云预处理结果,如图 9(c)、(d)所示。

3.4 道路测试中数据融合的结果分析

数据融合算法的结果如图 10 所示。
在数据融合阶段,首先对输入的图像数据采用改进的 YOLOX-Bit 网络进行目标检测,输出带有类别信息的目标边界框;对于输入的点云数据,经再处理与聚类操作后,得到点云聚类簇,从而获取交通锥的三维位置信息。本研究使用地面无人车(unmanned ground vehicle, UGV)在不同临时道路上开展户外实验。测试选用两种临时道路:直道与弯道。其中,直道长度约 24 m,弯道长度约 26 m;两




图 9 点云预处理
Fig. 9 Preprocessing for the point cloud




图 10 数据融合结果
Fig. 10 Data fusion result

种道路宽度均为 3 m,沿行驶方向的相邻交通锥间距为 2 m。蓝色与红色交通锥用于标识道路两侧,黄色交通锥用于标识道路起点与终点区域,UGV 将分别按照 1、1.5 和 2 m/s 的速度在直道与弯道中进行测试。

数据融合可视化如图 11(a)所示,黑色线条表匹配关系(线段越长投影误差越大),150 帧中 14 帧匹配错误(占 9.3%)。匹配错误主因同前(远距离、目标重叠),且点云投影与边界框过近也会致错。总体该框架直道检测定位精度达标。直道测试系统平均总耗时 31 ms,可实时处理(处理频率超传感器),各模块耗时占比:机器视觉检测 12.6 ms(40.6%)、点云预处理 7.6 ms(24.5%)、聚类 6.3 ms(20.3%)、数据融合 4.5 ms(14.6%)。

直道测试:本测试用 24 个交通锥(10 红、10 蓝、4 黄),机器视觉检测结果符合预期,但存在少量漏检。漏检主因是目标过小与重叠:原始图像缩放至 416×416 以降计算量,远处交通锥(小目标)易特征丢失。网络可在车前方 10 m 内准确检测,且图像每 33 ms 刷新,车辆行驶中可相继识别先前的漏检交通锥。点云算法可有效聚类,但偶尔漏检,是因为远距离锥反射激光不足,离散点低于聚类阈




图 11 场景测试结果
Fig. 11 Road test result

值被判定为噪声。直道锥线性排列,前方遮挡后方形成盲区,但随着车辆移动避开遮挡后,漏检交通锥可被检测。
弯道测试:弯道测试用 29 个交通锥(12 红、13 蓝、4 黄),结果符合预期。弯道图像中锥重叠少,但远距离锥误分类,因远处锥在图像中尺寸过小。点云检测结果稳定,漏检主因同直道。车速为 1.5 m/s 下数据融合结果如图 11(b)所示,311 帧中 35 帧匹配错误(占 11.3%),比直道多。因弯道锥布置密集,类别区分难、匹配精度降。总体该框架弯道性能与直道相近,满足检测定位需求。
分别在 1、1.5、2 m/s 下选取相同起点的 311 帧数据进行对比,错误率分别为 10.3%、11.3%、11.6%,错误率的

普遍提升及对速度的更高敏感性,主要归因于弯道中交通锥布置更密集、空间关系更复杂,增加匹配难度。尽管如此,该系统在弯道场景下的综合检测与定位精度仍能满足实际应用需求,进一步验证其在不同路径形态下的鲁棒性。

4 结 论

本研究提出一种结合图像检测与点云检测的交通锥检测与定位框架,通过融合两类检测结果,可同时获取交通锥的颜色信息与三维位置。为保障交通锥检测的实时性与准确性,本研究设计改进的YOLOX-Bit卷积神经网络;受库恩-蒙克雷斯算法启发,提出一种从全局角度确定边界框与点云聚类簇之间最优对应关系的数据融合算法。实车测试结果验证该框架的有效性。未来研究中,将引入深度学习方法,以更优地确定边界框与点云聚类簇之间的对应关系。

参考文献

- [1] 薛先斌,谭北海,余荣,等.基于行车风险场的交通冲突风险预警方法[J].电子测量技术,2024,47(6):1-7.
XUE X B, TAN B H, YU R, et al. Traffic conflict risk warning method based on driving risk field[J]. Electronic Measurement Technology, 2024, 47(6): 1-7.
- [2] KITAJIMA S, SHIMONO K, TAJIMA J, et al. Multi-agent traffic simulations to estimate the impact of automated technologies on safety[J]. Traffic Injury Prevention, 2019, 20: S58-S64.
- [3] 宋国正,朱可涵,李宏强,等.自动驾驶感知系统安全性定量测评方法研究[J].中国仪器仪表,2025(2):17-24.
SONG G ZH, ZHU K H, LI H Q, et al. Research on Safety evaluation method of autonomous vehicles' perception systems based on quantitative index[J]. China Instrumentation, 2025(2): 17-24.
- [4] 朱冰,范天昕,赵文博,等.自动驾驶汽车连续测试场景复杂度评估方法[J].吉林大学学报(工学版),2025,55(2):456-467.
ZHU B, FAN T X, ZHAO W B, et al. Continuous test scenario complexity evaluation method for automated driving vehicles [J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(2): 456-467.
- [5] 蔡炳彬,黄丹平,张浩田,等.基于机器视觉的轴承全表面缺陷在线检测方法[J].电子测量技术,2025,48(9):100-110.
CAI B B, HUANG D P, ZHANG H T, et al. Online detection method for full surface defects of bearings based on machine vision[J]. Electronic Measurement Technology, 2025, 48(9): 100-110.
- [6] 郑太雄,江明哲,冯明驰.基于视觉的采摘机器人目标识别与定位方法研究综述[J].仪器仪表学报,2021,42(9):28-51.
ZHENG T X, JIANG M ZH, FENG M CH. Vision based target recognition and location for picking robot: A review [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 28-51.
- [7] ZHANG Y, GUO ZH Y, WU J Q, et al. Real-time vehicle detection based on improved yolo v5 [J]. Sustainability, 2022, 14(19): 12274.
- [8] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [9] 李绪涛,邓耀华.电池字符缺陷检测DDP-YOLOv8模型方法[J].电子测量与仪器学报,2025,39(6):165-173.
LI X T, DENG Y H. DDP-YOLOv8 model for battery character defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 165-173.
- [10] SHE F, HONG Z, ZENG Z, et al. Improved traffic sign detection model based on YOLOv7-tiny[J]. IEEE Access, 2023, 11: 126555-126567.
- [11] 王海群,武泽锴,晁帅.改进YOLOv8n的遥感图像目标检测算法[J].电子测量与仪器学报,2025,39(4):84-94.
WANG H Q, WU Z K, CHAO SH. Improved the YOLOv8n object detection algorithm for remote sensing images[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 84-94.
- [12] GE Z, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv preprint arXiv: 2107.08430, 2021.
- [13] 郝飞,焦云东,孙佳浩,等.正交远心机器视觉测量方法及其系统与应用[J].仪器仪表学报,2025,46(9):125-133.
HAO F, JIAO Y D, SUN J H, et al. Orthogonal telecentric machine vision measurement method and its system and application [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 125-133.
- [14] 马志艳,邵长松,杨光友,等.同步定位与建图技术研究进展[J].电光与控制,2023,30(3):78.
MA ZH Y, SHAO CH S, YANG G Y, et al. Research progress of simultaneous localization and

- mapping technology [J]. Electronics Optics & Control, 2023, 30(3): 78.
- [15] 裴凌,李涛,花彤,等.多源融合定位算法综述[J]. 南京信息工程大学学报(自然科学版), 2022,14(6):635-648.
- PEI L, LI T, HUA T, et al. A survey of multi-source fusion positioning algorithms[J]. Journal of Nanjing University of Information Science & Technology(Natural Science Edition), 2022, 14(6): 635-648.
- [16] 张普,刘金清,肖金超,等.基于相机与激光雷达融合的目标定位与跟踪[J]. 激光与光电子学进展, 2024, 61(8): 315-323.
- ZHANG P, LIU J Q, XIAO J CH, et al. Target localization and tracking method based on camera and lidar fusion[J]. Laser & Optoelectronics Progress, 2024, 61(8): 315-323.
- [17] DU Y CH, QIN B H, ZHAO C, et al. A novel spatio-temporal synchronization method of roadside asynchronous MMW radar-camera for sensor fusion [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(11): 22278-22289.
- [18] PNEG J, ZHANG P, ZHENG L X, et al. UAV positioning based on multi-sensor fusion[J]. IEEE Access, 2020, 8: 34455-34467.
- [19] ZHAO Z Y, CUI H, DU K, et al. Calibration method of 3D laser projection based on homography matrix[J]. Acta Photonica Sinica, 2022, 51(11): 1112001.

作者简介

王立勇,教授,主要研究方向为机电系统智能感知与控制、智能与新能源汽车和技术。

E-mail:wangliyong@bistu.edu.cn

崔傲,硕士研究生,主要研究方向为车辆无人驾驶技术。

E-mail:13674337221@163.com

苏清华(通信作者),副研究员,主要研究方向为移动机器人、自动驾驶与生物传感器工程等。

E-mail:suqinghua@bistu.edu.cn

王浩东,博士研究生,主要研究方向为非结构化道路自动驾驶。

E-mail:hdwang@bit.edu.cn

宋越,助理研究员,主要研究方向为无人驾驶车辆环境感知、高精度地图构建。

E-mail:songyue597@163.com