

雷达和视频融合技术下小目标车辆检测方法

杜传祥¹, 魏秀岭¹, 巨永锋², 邹德宁¹

(1. 西安思源学院 工学院, 西安 710038; 2. 西安思源学院 学科办公室, 西安 710038)

摘要: 针对复杂道路交通场景下小目标车辆检测难题, 提出基于雷达和视频融合的检测方法; 采用将 K-means 聚类算法与 YOLOv5 网络损失函数深度融合的方法, 构建联合识别框架, 通过雷达点云聚类提取空间位置信息, 利用 YOLOv5 网络提取视觉特征, 实现优势互补, 并设计联合损失函数平衡两种模态信息贡献度; 在复杂道路交通场景下, 对 YOLOv5 网络进行改进, 引入多尺度特征融合与增强技术, 结合雷达点云聚类结果进一步增强特征; 实验结果表明, 该方法结合雷达与视频技术优势, 有效提高了复杂道路交通环境下小目标车辆的检测精度。

关键词: 雷达技术; 云信息聚类; 视频技术; 目标检测; 道路交通网络; 小目标车辆

A Small Target Vehicle Detection Method based on Radar and Video Fusion Technology

DU Chuanxiang¹, WEI Xiuling¹, JU Yongfeng², ZOU Dening¹

(1. School of Engineering, Xi'an Siyuan University, Xi'an 710038, China;

2. Discipline Office, Xi'an Siyuan University, Xi'an 710038, China)

Abstract: To address the challenge of detecting small target vehicles in complex road traffic scenarios, a detection method based on radar and video fusion is proposed. A joint recognition framework is constructed by deeply integrating the K-means clustering algorithm with the YOLOv5 network loss function. The spatial position information is extracted through radar point cloud clustering, and the YOLOv5 network is used to extract visual features to achieve complementary advantages, and to design a joint loss function to balance the contribution of two modal information. In complex road traffic scenarios, the multi-scale feature fusion and enhancement techniques are introduced to improve the YOLOv5 network, and to further enhance the feature by combined with radar point cloud clustering results. Experimental results show that this method combines the advantages of radar and video technology, effectively improving the detection accuracy of small target vehicles in complex road traffic environments.

Keywords: radar technology; cloud information clustering; video technology; object detection; road traffic network; small target vehicles

0 引言

复杂道路交通是指由于交通流量、道路条件等多种因素交织, 导致行车难度增加、风险提升、环境复杂的道路交通状况。该类型交通网络包括多路交叉口、畸形交叉口等多种不同的场景, 且在某些特殊条件下(如道

路施工、恶劣天气等), 道路交通情况可能变得更加极端, 由于道路交通状况的持续变化, 其复杂程度也在随之改变, 而这也使得车辆所面临的行驶风险不断提升^[1]。在复杂的道路交通网络中, 车辆速度突变、邻车遮挡等问题偶有发生, 不但影响车辆的行驶稳定性, 还会影响交通系统主机对车辆的跟踪与检测, 进而导致各

收稿日期:2025-05-14; 修回日期:2025-06-17。

基金项目:西安思源学院校长基金项目(自然科学类重点项目)(XASYZD-B2302;XASYB24ZD04)。

作者简介:杜传祥(1979-),男,硕士,副教授。

魏秀岭(1979-),男,硕士,副教授。

巨永锋(1962-),男,博士,教授。

邹德宁(1964-),女,博士,教授。

引用格式:杜传祥,魏秀岭,巨永锋,等. 雷达和视频融合技术下小目标车辆检测方法[J]. 计算机测量与控制, 2026, 34(4): 49-56, 64.

级管理部门无法实时获取道路交通信息,难以监管道路上的行驶车辆。

以往研究对于复杂道路交通网络行车目标的检测涉及如下几种方法,如江志鹏等人^[2]提出的基于改进 Deformable DETR 的检测算法,利用跨尺度特征融合模块增大相机感受野,根据关键目标的响应值,设计核心检测函数,再使用困难样本挖掘技术,改善数据样本的分布均匀度,进而获得目标车辆检测结果。由于复杂道路交通网络中行驶车辆的数量较多,所以利用该方法检测重要目标,容易出现漏检或错检的问题。董亮等人^[3]提出了融合注意力机制与边缘计算的检测算法,基于多维协作注意机制改进 YOLOv5 的主干网络,再以多分支卷积模块替换原 CBL 模块,最后通过连续训练车辆行驶数据,实现对目标车辆的检测。边缘计算意在通过小样本运算推导唯一的定义法则,所以基于该机制所定义的检测算法并不适用于多样化的复杂道路交通网络环境。程鑫等人^[4]提出了基于体素柱形的检测算法,以体素特征图为基础构造柱形,并通过特征编码的方式,定义目标车辆信息,再参考混合置信度参量,训练目标行驶车辆的样本数据,实施针对性检测。但混合置信度参量的取值相对较为局限,故该方法所得检测结果的准确性有待提升。古佳欣等人^[5]提出了基于改进 YOLOv8n 的检测算法,重构 YOLOv8n 主干网络,并添加 P2 检测层以定位小目标对象,同时对所得数据的特征参量进行多尺度融合,定义多样化的检测方案。YOLOv8n 网络具有实时更新输入数据的特性,所以在检测小目标车辆的过程中,容易因数据受限而获得非准确的识别结果。

在多目标跟踪检测任务中,需要连续地跟踪多个目标,如车辆、行人等。为了实现这一目标,系统必须能够连续地获取并处理包含这些目标的图像帧。这些连续帧图像使算法能够在每一帧图像中实时更新目标的位置和状态,如何准确地将检测到的目标与前一帧或后一帧中的目标进行关联,形成稳定的轨迹,是一个复杂的问题。为解决上述问题,提出雷达和视频融合技术下小目标车辆检测方法。将 K-means 聚类算法与 YOLOv5 网络损失函数深度融合,通过动态权重系数实现了视觉特征与点云聚类信息的自适应融合。这种融合机制突破了单模态检测的局限性,显著提升了复杂场景下的目标识别可靠性。在 YOLOv5 架构中构建了多尺度特征增强模块,通过层级特征融合与雷达点云先验知识注入,解决了小目标车辆特征表示不足的难题提出基于高斯投影的异构空间转换方法,引入车辆动力学参数约束的误差校正机制,实现了毫米级精度的坐标转换。融合运动状态估计的跟踪参数动态调整机制,通过反向跟踪向量和轨迹偏移系数的联合优化,在交通拥堵场景下仍保持跟

踪稳定性。

1 基于雷达和视频融合的车辆识别

在当前的小目标车辆检测过程中,雷达点云聚类与视频目标检测多为独立处理,缺乏深度融合。对此,本文将 K-means 聚类算法与 YOLOv5 网络损失函数进行深度融合,构建了一个联合识别框架。通过雷达点云聚类提取目标的精确空间位置信息,同时利用 YOLOv5 网络提取目标的丰富视觉特征,实现了两种模态信息的优势互补。并在融合过程中设计了一种联合损失函数,该函数综合考虑了雷达点云聚类结果与 YOLOv5 视频目标检测结果的差异。通过引入权重系数,平衡了两种模态信息在识别过程中的贡献度,使识别结果更加准确可靠。

1.1 雷达点云信息聚类

雷达设备(如毫米波雷达、激光雷达等)会向周围环境发射特定频率的电磁波信号。当这些信号遇到目标物体(如小目标车辆)时,会发生反射。雷达设备接收到反射信号后,通过测量信号的发射时间、接收时间以及信号的频率变化等信息,利用相关算法计算出目标物体与雷达之间的距离、方位角和俯仰角等参数。这些参数经过转换和处理后,就可以得到目标物体在三维空间中的坐标信息,众多目标物体的坐标信息集合就构成了雷达点云。

利用雷达识别技术标定视频图像中小目标车辆,关键在于对雷达点云信息的有效处理与聚类分析。针对雷达获取的点云数据,进行滤波处理以去除离群样点和噪声参量,确保数据质量。计算雷达目标边界框,通过定义中心点位置,并根据输入信息数量级水平设置长度、宽度与高度值,得到符合点云信息实时输入量的目标边界框,这一过程明确了目标在点云数据中的尺寸和位置。

在雷达点云信息聚类中,确定聚类簇的数量是关键问题,采用肘部法则,通过计算不同簇数下簇内误差平方和(SSE),绘制 SSE 随簇数变化的曲线,当曲线出现明显拐点时,该拐点对应的簇数即为较合适的聚类数量。也可借助轮廓系数法,计算每个数据点的轮廓系数,轮廓系数取值范围在 $-1\sim 1$ 之间,值越大表示聚类效果越好,通过比较不同簇数下的平均轮廓系数,选择平均轮廓系数最大的簇数。

对于聚类结果中的噪声点处理,设定距离阈值,若某点到其所属簇中心的距离超过该阈值,则判定为噪声点并剔除。在此基础之上,运用 K-means 聚类算法,对雷达目标边界框内的点云信息进行聚类运算。该算法基于标定距离值,将点云数据划分为多个相似度高且彼此差异大的簇。通过迭代优化簇心,使簇内数据紧凑度达到最优。从簇中定义随机点代表簇中心,计算点云参

量到边界框中心点的距离, 直至簇中心取值稳定。最终, 根据聚类结果识别不同小目标车辆, 提取其点云特征, 并分析聚类中心移动轨迹, 以此判断小目标车辆的行进意图与运动状态, 从而实现视频图像中小目标车辆的精准标定。

1) 雷达目标边界框计算:

在雷达目标检测中, 边界框标示出了所检测到目标对象在点云数据以及雷达图像中的尺寸和位置。该结构由一组坐标定义, 而这些坐标可以用来表示目标外部的最小外接矩形。计算边界框时, 用来描述目标的尺寸和位置信息需要表示在同一坐标系下^[6-7]。由于雷达测量数据的分布并不局限于一种形式, 所以在计算目标边界框时, 应优先对点云数据进行滤波处理, 以去除离群样点和噪声参量。

在检测目标外部的最小外接矩形中, 定义中心点位置, 并将选定样点直接作为雷达目标边界框的中心点。为精准检测点云信息, 根据输入信息的数量级水平设置长度、宽度与高度值, 将其作为定义中心点的基准参考条件, 进而确保所生成目标边界框能够符合点云信息的实时输入量^[8]。设 a 为检测目标外部最小外接矩形的长度值, s 为宽度值, d 为高度值, 且 $a \neq 0$ 、 $s \neq 0$ 、 $d \neq 0$ 的不等式取值条件同时成立, ΔA 为雷达点云信息的单位输入量, 基于上述物理量, 可将雷达目标边界框计算式表示为:

$$F = \frac{asd}{2^3} |\Delta A| \cdot \left(\sum_{\alpha=1}^{+\infty} \beta \tilde{S} \right) \quad (1)$$

α 为点云数据的滤波运算参数, β 为噪声信息去除项, \tilde{S} 为所输入点云数据的离群样点定义参量。在雷达目标边界框中进行聚类运算, 可以分辨出所输入点云数据中是否存在相互覆盖的情况, 由于上述计算已经滤除了噪声信息与离群样点, 所以即便对输入数据进行连续运算, 也不会造成准确性受限的问题。

2) K-means 聚类:

利用目标边界框进行 K-means 聚类运算, 可以实现对雷达点云信息的完全聚类处理, 但前提是要事先知道数据样本的类别数量。K-means 聚类是基于标定距离值的非监督学习算法, 其核心思想是将输入数据划分为多个簇对象, 且每个簇内所包含数据点应尽可能相似, 但不同簇所包含数据点则应尽可能不同^[9]。该算法通过对簇心的迭代优化, 逐步使每个簇内部数据的紧凑度达到最优状态。在雷达目标边界框中, 将小目标车辆雷达点云信息的数据集划分为 χ 个具有相同特征的簇组织, 从所获得的簇中定义 δ 个随机点用来代替点云簇的中心位置。分别计算这些点云参量到雷达目标边界框中心点的距离, 重复上述步骤, 直至点云簇中心的取值不再发生变化。规定 O 表示雷达目标边界框的中心点, 其坐

标为 (D_1, D_2, D_3) , 该节点与公式 (1) 之间存在如下表达式所示的取值关系:

$$O(D_1, D_2, D_3) \in F \quad (2)$$

联立簇组织 χ 与随机点 δ , 可将雷达点云信息的 K-means 聚类表达式定义为:

$$G = f \frac{|D_1 - g_1| \cdot |D_2 - g_2| \cdot |D_3 - g_3|}{\chi^\delta} \quad (3)$$

g_1 、 g_2 、 g_3 分别为聚类距离在不同监测方向上的数值分量, f 为簇内雷达点云信息的紧凑度。根据 K-means 聚类结果, 雷达传感器可以识别出不同的小目标车辆, 若将其定义为检测目标, 则可以提取其点云特征, 再通过对聚类中心移动轨迹的分析, 就可以进一步判断小目标车辆的行进意图与运动状态, 进而保障车辆检测目标的定义精度。

1.2 视频目标检测

针对复杂道路交通场景中中小目标车辆检测的难点, 对 YOLOv5 网络中的锚点自适应调整技术进行了改进。为了充分利用视频图像中的多尺度信息, 在 YOLOv5 网络中引入了多尺度特征融合与增强技术。通过 PANet 特征金字塔对不同尺度的特征进行融合处理, 提高了网络对小目标车辆的检测能力。同时, 结合雷达点云聚类结果, 对融合后的特征进行进一步增强处理, 使网络能够更加准确地识别出小目标车辆。

1.2.1 YOLOv5 网络总体构建

YOLOv5 是一种新型的目标信号采集网络架构, 由 CSPDarknet53 骨干网络、锚点自适应调整技术及 PANet 特征金字塔 3 部分共同组成。在复杂道路交通系统中, 基于 YOLOv5 网络检测视频目标, 可以在保持更好检测精度的同时, 提升传感器主机对目标对象的识别速度^[10]。CSPDarknet53 骨干网络的设置采用跨阶段局部网络的布局形式, 通过对特征图通道的合并处理, 增强 YOLOv5 系统对输入目标的学习处理能力, 同时降低了目标检测的实时计算量。锚点自适应调整技术根据数据集特点调整目标锚点的数量与尺寸, 从而使得 YOLOv5 系统模型的运算能够更好地适应复杂道路交通场景中的小目标车辆检测需求。PANet 特征金字塔同时实施自底向上和自顶向下的路径增强处理, 可在不同尺度特征条件下对目标对象进行融合, 提高了 YOLOv5 系统模型对小目标车辆的检测能力^[11]。复杂道路交通网络中, 小目标车辆检测目标具有多变性的特点, 故利用 YOLOv5 架构模型实施检测, 还应使用高性能组件 (如 GPU 加速等) 提高模型推理速度, 从而进一步满足实时性要求。完整的 YOLOv5 网络架构模型如图 1 所示。

YOLOv5 网络模型具有极高的检测速度, 能够满足复杂道路交通场景下系统主机对小目标车辆的实时性检

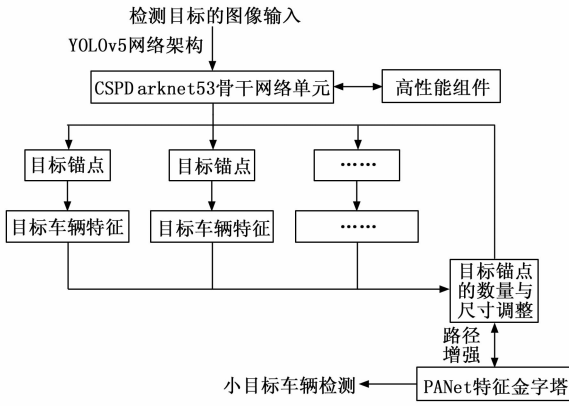


图 1 YOLOv5 网络的架构模型

测要求。这使得它能够在视频流中实时检测小目标车辆，为智能交通系统提供有力的图像信息支持。

1.2.2 目标损失函数求解

在视频图像中，为实现对复杂道路交通小目标车辆的检测，YOLOv5 总损失函数的定义包括分类损失、边界框回归损失、置信度损失三部分内容，共同训练这些损失函数并将其应用于小目标车辆的选取与定义，以确保能够准确的检测行驶车辆。分类损失用于衡量预测框中车辆目标类别与真实视频对象之间的差异^[12]。在 YOLOv5 网络模型中，这一损失条件的计算遵循二元交叉熵损失函数，具体定义式为：

$$H_1 = - \sum_{\epsilon=1}^{+\infty} [\varphi \ln(hj_\gamma)] \quad (4)$$

γ 为视频图像中的车辆目标类别定义项， j_γ 为 γ 车辆对象的定义参量， h 为二元交叉熵参数， ϵ 为差异性衡量值， φ 为交叉熵损失值。边界框回归损失能够衡量视频图像中小目标车辆预测边界框与真实边界框之间的差异。在 YOLOv5 网络中，这一损失条件的定义遵循 CIoU 损失函数。对于 YOLOv5 网络模型边界框回归损失函数的定义参考式 (5)：

$$H_2 = \varphi(4 \times j_\gamma^{\text{small}} + 1 \times j_\gamma^{\text{medium}} + 0.4 j_\gamma^{\text{large}}) \quad (5)$$

j_γ^{small} 为车辆对象 γ 在小预测特征层中的边界框回归值， j_γ^{medium} 为中预测特征层中的边界框回归值， j_γ^{large} 为大预测特征层中的边界框回归值， φ 为 CIoU 损失定义值。置信度损失用于衡量视频图像的预测框中是否存在车辆目标概率与真实情况之间的差异。在 YOLOv5 网络中，这一损失条件通常使用加权损失函数来计算。加权损失函数能够很好处理复杂道路交通网络中小目标车辆的二分类问题，即判断视频图像预测框中是否存在小目标车辆对象。基于加权损失函数推导 YOLOv5 置信度损失函数表达式为：

$$H_3 = \frac{j_\gamma^{-1}}{\bar{k}(1-\epsilon)} \quad (6)$$

ϵ 为视频图像中小目标车辆的二分类系数， \bar{k} 为车

辆目标概率的加权损失向量。联立公式 (4) ~ (6)，可将复杂道路交通网络中车辆视频目标的 YOLOv5 损失函数定义式表示为：

$$H = \kappa_1 H_1 + \kappa_2 H_2 + \kappa_3 H_3 \quad (7)$$

κ_1 、 κ_2 、 κ_3 分别为 3 部分损失的平衡参数。因为视频图像中小目标车辆种类繁多，YOLOv5 网络模型需要准确识别出不同种类的车辆。通过对各项目标损失值的计算，模型可以更好区分出不同类别的车辆目标，从而使检测精度得到保障。

1.3 雷达和视频融合下的车辆识别参数求取

将雷达点云聚类结果与 YOLOv5 检测结果进行融合，求取雷达和视频融合下的车辆识别参数。联立公式 (3)、(7)，推导雷达点云信息聚类与 YOLOv5 视频目标检测算法的融合运算式为：

$$J = (G^{-1} + H^{-1}) \cdot \left(\sum_{o \rightarrow \infty} \vec{K} \right)^{-1} \quad (8)$$

o 为目标检测特征的融合系数， \vec{K} 为目标车辆信息在雷达和视频图像中的关联向量。基于雷达和视频融合求解小目标车辆在复杂道路交通网络中的识别参数，应确保高清摄像机具备足够的分辨率，以捕捉小目标车辆在行进过程中的细节信息。由于车辆在行进过程中保持快速移动状态，所以为捕捉到清晰的图像，应确保摄像机的帧率水平足够高^[13]。此外，光照变化也会对雷达和视频图像的质量造成影响，所以在求取车辆识别参数时，还应参考中值滤波标准，去除原图像中噪声参量，以减少噪声信息对小目标车辆边界识别的影响。利用公式 (8)，可将雷达和视频融合下的车辆识别参数计算式表示为：

$$L = 1 - \left(\lambda \left| \frac{\bar{l}}{J} \right|^2 + \sqrt{\mu p} \right)^\nu \quad (9)$$

式中， λ 为高清摄像机的帧率值， \bar{l} 为小目标车辆的移动速率， μ 为视频图像的质量参数， p 为光照强度， ν 为中值滤波系数。通过将雷达的精确空间位置信息与视频的丰富视觉特征相结合，可以充分发挥两者的优势，弥补各自的不足。公式 (9) 中的 L 是雷达和视频融合下的车辆识别参数，其综合考虑了高清摄像机的帧率值、小目标车辆的移动速率、视频图像的质量参数、光照强度和中值滤波系数等因素。通过计算 L ，可以得到融合后的车辆识别参数，这些参数可以用于后续的目标跟踪、行为分析等任务。雷达和视频融合下的车辆识别参数求取，就是结合雷达点云信息聚类与 YOLOv5 视频目标检测算法^[14]，在确保雷达数据、视频数据在时间上处于同步态势的基础上，将同时满足两项表达式标准的目标车辆定义系数筛选出来。

在复杂道路交通场景中，小目标车辆检测面临着诸多独特挑战。小目标车辆在图像中所占像素区域较小，其外观特征不够明显，容易被背景噪声或其他物体干

扰,导致传统检测方法难以准确识别。同时,由于小目标车辆尺寸小,在雷达点云数据中,其反射信号相对较弱,点云分布较为稀疏,增加了点云聚类 and 特征提取的难度。

通过改进雷达点云聚类算法和 YOLOv5 视频目标检测网络,实现了雷达与视频模态信息的深度融合,旨在提升对小目标车辆的检测能力。雷达点云聚类能够提取小目标车辆的精确空间位置信息,而 YOLOv5 网络则擅长提取目标的丰富视觉特征,两者的融合可充分发挥各自优势,弥补小目标车辆特征不明显的不足。

在此基础上,第2节进一步聚焦于复杂道路网络中的小目标车辆检测问题。为了更精确地描述小目标车辆的运动状态和位置信息,提出了一种高精度的空间坐标系转换方法,并结合小目标数据采集、增强与特征重构等手段,全面提升对小目标车辆的检测精度和可靠性,从而更好地应对复杂道路交通场景下小目标车辆检测的难题。

2 复杂道路交通的小目标车辆检测

针对复杂道路网络中的空间坐标系转换问题,提出了一种高精度的空间坐标系转换方法。该方法基于雷达和视频融合技术识别所得的车辆参数,结合高斯平面直角坐标系和椭球基准,通过高斯投影的方式实现了雷达和视频图像中目标车辆位置信息的精确转换。同时,引入了误差校正机制,对转换过程中的误差进行了有效校正,提高了转换结果的准确性。

2.1 复杂道路网络的空间坐标系转换

在复杂道路网络中,转换小目标车辆空间坐标系以高斯平面直角坐标系为基础。其中, X 轴为横轴,正方向指向东; Y 轴为纵轴,正方向指向北; Z 轴为空间轴,正方向与空间法向量的正方向保持一致^[15]。结合车辆行驶特点可知,方位角的测量始终与正北方向为标准,并按照顺时针方向进行连续计算。为保证坐标系与道路网络标识的高度重合,应明确转换的起点和终点坐标系,并确定目标样点的转换精度要求。对于高斯平面直角坐标系的定义采用椭球基准,涉及长短轴、扁率两项基本信息^[16]。通过高斯投影的方式,将椭球原点定义在平面直角坐标系的原点位置处,在确保两个坐标系中至少有3个重合点坐标的前提下,定义具体的坐标系转换标准。设 (X_1, Y_1, Z_1) 、 (X_2, Y_2, Z_2) 、 (X_3, Y_3, Z_3) 为3个已知的重合点坐标,且 $X_1 \neq X_2 \neq X_3 \neq 0$ 、 $Y_1 \neq Y_2 \neq Y_3 \neq 0$ 、 $Z_1 \neq Z_2 \neq Z_3 \neq 0$ 的不等式取值条件同时成立, \vec{P} 为高斯平面直角坐标系的空间法向量,联立公式(9),可将复杂道路网络的空间坐标系转换定义式表示为:

$$O_{xyz} = \frac{\vec{P}}{Li_0^2} \times \left(\left| \frac{X_1 X_2 X_3}{\sin \vartheta_x} \right| \cdot \left| \frac{Y_1 Y_2 Y_3}{\sin \vartheta_y} \right| \cdot \left| \frac{Z_1 Z_2 Z_3}{\sin \vartheta_z} \right| \right) \quad (10)$$

o 为椭球短轴参数, i 为椭球扁率参数, ϑ_x 为空间法向量与 X 轴的夹角, ϑ_y 为空间法向量与 Y 轴的夹角, ϑ_z 为空间法向量与 Z 轴的夹角。利用选定的转换方法和雷达和视频融合技术识别所得的车辆参数,执行坐标转换,且在转换过程中,应严格控制各项物理量的计算精度,以确保转换结果的准确性。

2.2 空间坐标系中的小目标数据采集

为了更精确描述小目标车辆在复杂道路网络内的运动状态,在公式(10)所示的坐标系中,以道路的行驶路径为参考基线,将车辆的位置和运动状态投影到这条参考基线上。在以高斯平面直角坐标系为基础定义的复杂道路网络坐标系中,小目标车辆的位置可用沿参考基线的纵向距离和垂直于参考基线的横向距离共同表示^[17]。设 I 表示小目标车辆位置沿参考基线的纵向距离, U 表示垂直于参考基线的横向距离,二者不互为相关参数条件,联立公式(10),求解横、纵距离在复杂道路网络空间坐标系中所对应投影向量 T_I 与 T_U 的计算结果为:

$$\begin{cases} T_I = -\frac{\theta_I I}{O_{xyz}} \cdot \ln(t_I) \\ T_U = U \ln(t_U) + \theta_U O_{xyz} \end{cases} \quad (11)$$

式中, t_I 为横向距离参数在雷达和视频图像中的投影参量, θ_I 为水平法向量与参考基线的距离, t_U 为纵向距离参数在雷达和视频图像中的投影参量, θ_U 为竖直法向量与参考基线的距离。利用公式(11),推导空间坐标系中的小目标车辆数据的采集定义式为:

$$R = \frac{1}{(T_I T_U)^{-\omega}} \cdot \frac{\vec{r}}{\sum_{e=1}^{+\infty} \hat{E}} \quad (12)$$

其中: ω 为小目标车辆的像素覆盖参数, \vec{r} 为小目标车辆数据的采集基向量, e 为雷达和视频图像中小目标车辆的像素区域定义项, \hat{E} 为小目标数据分类特征。在雷达和视频图像中,小目标车辆指的是占据较小像素区域的行驶车辆^[18]。由于该类型车辆覆盖的区域相对较小,所以其位置缺少多样性,在采集小目标数据时,若像素区域内的车辆边界清晰度欠佳,则可以通过速度或加速度参量进行运算。

2.3 小目标数据增强

空间坐标系中采集所得的小目标车辆数据仅具有一般性的描述能力,若基于这些物理量进行计算,并不能实现对行驶车辆的完全精准检测。因此,为提升小目标车辆数据的描述能力,应在复杂道路网络中,对所得数据样本进行增强处理。

首先,在雷达和视频图像上多次复制粘贴小目标车辆,以增加车辆对象的训练样本数目^[19]。由于每个图像帧中小目标对象的数量都有所增加,所以与之匹配的

anchor 数量也会随之增加,在后续检测过程中,该处理流程有助于提升小目标在训练阶段对 loss 计算的贡献。然后,对小目标车辆进行缩放、翻折、旋转等变换处理,以增加采样数据的多样性。最后,通过放大和裁剪操作得到不同大小的图像,使车辆目标在图像中的位置和占比发生变化,增强了模型对车辆目标所在位置及大小的鲁棒性。在实际道路场景中,小目标车辆的位置和大小会因距离、拍摄角度等因素而变化,经过这种数据增强处理后的模型能够更好地适应这些变化,在不同位置和大小情况下都能准确检测出小目标车辆,提高了模型在实际应用中的可靠性^[20]。在公式(12)的基础上,可将小目标车辆数据的增强运算表达式定义为:

$$W = (1 - q\omega)R + u\dot{Q} \quad (13)$$

式中, q 为图像帧中与小目标车辆对象匹配的 anchor 数量, ω 为小目标车辆数据训练过程中的 loss 计算值, u 为针对小目标车辆的变换操作参数, \dot{Q} 为小目标车辆在雷达和视频图像中的位置占比特征。在进行数据增强时,需要避免引入过多的噪声或不合理的数据变换,以免损害复杂道路网络对小目标车辆特征的提取性能。

2.4 小目标车辆特征重构

将含有小目标增强数据的车辆图像重复加入训练集中,以增加小目标样本在雷达和视频图像中的实时数量。针对实时小目标车辆数据进行过采样,但需要注意控制过采样率,以避免发生数据不平衡的问题^[21]。将小目标车辆从一张图像中复制到另一张图像中的任意位置,并生成新的标注,融合两张图像为目标车辆特征的重构提供参考。重构复杂道路交通小目标车辆特征,涉及特征提取、特征融合、重构方案定义 3 个环节。特征提取的过程中需要注意保留小目标车辆的细节信息,避免信息丢失^[22]。将提取到的车辆特征进行融合,以得到更全面的车辆特征表达形式。在特征融合的基础上,对车辆特征进行重构,从而得到更加准确和鲁棒的车辆特征表示。设 V 为小目标增强数据的过采样率, c 为目标车辆复制标注, v_c 为原图像与复制图像的融合参数, b_0 为小目标车辆细节信息的原取样向量, τ 为特征参数, b_τ 为 τ 参数条件下的小目标车辆细节信息取样向量, Δb 为待融合小目标增强数据的单位取样量, 联立公式(13), 定义复杂道路交通小目标车辆特征重构表达式如下:

$$C = \sum_{c \in (0,1]} V(v_c) \cdot W(b_0 + b_\tau + \Delta b) \quad (14)$$

合理的数据增强有助于保障小目标车辆特征重构的准确性,在复杂道路交通环境中,针对重构后的车辆特征进行检测,能够避免所得雷达和视频图像中出现数据信息相互覆盖的问题。

2.5 跟踪标准定义与车辆检测

小目标车辆跟踪是实现复杂道路网络中车辆对象检测的必要环节,针对小目标车辆在复杂道路网络中的跟踪难点,提出了一种动态跟踪标准定义方法。该方法结合车辆的速度、加速度等运动状态信息,以及雷达和视频图像中的位置信息,实时调整跟踪参数和条件,实现了对小目标车辆的持续识别和定位。同时,引入了反向跟踪向量和轨迹偏移系数等概念,提高了跟踪的准确性和稳定性。

利用重构后的小目标车辆特征,在连续的雷达和视频图像序列中,对小尺寸、低分辨率或难以识别的车辆目标进行持续识别与定位,并获取行驶车辆的运动轨迹和状态信息。在连续的图像帧中,检测小目标车辆需要对车辆对象进行持续跟踪^[23]。由于车辆运动轨迹中可能包含遮挡、交叉、目标突然消失或重新出现等问题,所以在定义跟踪条件时,应实时关注车辆速度与加速度的变化情况。对于小目标车辆跟踪标准的定义参考如下表达式:

$$B = \text{softmax}\left(\frac{\zeta N^n}{\sqrt{C}}\right) \quad (15)$$

式中, N 为小目标车辆的状态信息, ζ 为行驶车辆的轨迹状态参量, n 为实时跟踪系数。检测小目标车辆就是根据实时跟踪条件,对所选定车辆进行按需识别。由于实时跟踪条件的定义考虑了车辆运动轨迹中可能出现的问题,所以在实施检测时,不需对目标车辆的行进轨迹进行额外处理^[24]。在公式(15)的基础上,推导复杂道路交通小目标车辆的检测表达式为:

$$M = (\psi + 1)^\omega B^v \log(\bar{m}) \quad (16)$$

式中, ψ 为小目标车辆的运动轨迹偏移系数, ω 为反向跟踪向量, v 为小目标车辆的行驶加速度, \bar{m} 为跟踪过程中小目标车辆的平均行驶速度。基于雷达和视频融合的复杂道路交通小目标车辆检测方法结合了雷达点云聚类与视频图像识别的先进技术,旨在提高复杂道路交通环境下小目标车辆的检测精度。

3 实验分析与研究

利用雷达技术标定视频图像中的小目标车辆,滤除检测框外的无关样点,并通过时间同步处理将标定后的识别框投影到二维平面,效果如图 2 所示。



图 2 视频图像中小目标车辆的雷达识别样点标定

多次重复标定, 直至筛选出实验所需的全部小目标车辆, 为避免单一性检测对实验结果的准确性造成影响, 所选定实验对象应同时占据同向与对象车道, 如图 3 所示。




图 3 小目标车辆检测的实验原理

检测主机通过工业相机捕捉小目标车辆在道路交通网络中的行驶图像, 本次实验所选工业相机的相关参数情况如表 1 所示。

表 1 实验相机参数

项目	相机属性	参数
1	工业相机	LRCP7650
2	接口	USB 3.0
3	像素大小	$3.55 \mu\text{m} \times 3.55 \mu\text{m}$
4	分辨率	720×1280
5	信噪比	36 dB
6	采样速度	35 帧/秒

工业相机采集到的小目标车辆图像通过局域网反馈的方式传输至检测主机之中, 因此实验过程中不会出现像素信息损失的情况。基于上述实验准备, 给出主要实验步骤如下:

- 1) 将选定样点直接作为雷达目标边界框的中心点, 计算雷达目标边界框 F ;
- 2) 采用 K-means 聚类方法, 对目标边界框进行聚类运算, 获取聚类结果 G ;
- 3) 建立 YOLOv5 网络架构, 求解目标损失函数 H_1 , 获取复杂道路交通网络中车辆视频目标的 YOLOv5 损失函数 H ;
- 4) 对复杂道路交通网络的空间坐标系进行转换 O_{xyz} , 采集小目标数据信息 R ;
- 5) 增强小目标车辆数据 W , 重构车辆特征 C , 定义小目标车辆跟踪标准, 实现对小目标车辆的检测。

设置离群点判断阈值为 0.5, 噪声去除阈值为 0.3, 输入点云数据数量级对应的典型小目标车辆尺寸为长 2 m, 宽 1.5 m, 高 1.2 m, 聚类簇的数量为 3, 初始目标锚点数量为 9 个, 小目标车辆移动速率为 15 m/s, 视频图像质量参数为 0.9。

在车辆识别图像清晰度保持恒定的情况下, 以小目标车辆与相机传感器之间的距离作为研究对象, 若不考虑其他干扰条件的影响, 检测车辆与相机传感器

的距离越远, 就表示主机能够准确检测出小目标车辆的可能性越大。检测主机对小目标车辆的识别精度标准如图 4 所示。



图 4 车辆识别图像的清晰度标准

应用基于雷达和视频融合的复杂道路交通小目标车辆检测方法 (第 1 组)、基于改进 Deformable DETR 的检测算法 (文献 [2] 方法, 第 2 组)、融合注意力机制与边缘计算的检测算法 (文献 [3] 方法, 第 3 组) 进行实验, 在获得较为清晰识别图像的基础上, 分析小目标车辆与相机传感器之间的距离, 具体实验情况如图 5 所示。




图 5 小目标车辆与相机传感器的距离

分析图 5 可知, 基于第 1 组方法进行检测, 小目标车辆与相机传感器距离的最大值达到 63.6 m, 其检测结果的最小值也达到 40.1 m。基于第 2 组方法进行检测, 小目标车辆与相机传感器距离的均值水平相对较低, 其最大值为 54.7 m, 小于第 1 组的当前实验结果, 也小于第 1 组的最大检测值。基于第 3 组方法进行检测, 小目标车辆与相机传感器距离的均值水平也相对较低, 其最大值为 52.5 m, 虽然大于第 1 组的当前实验结果, 但小于第 1 组的最大检测值。

综上, 若以小目标车辆与相机传感器之间的距离作为研究对象, 很明显第 1 组实验方法的可行性更强。

在小目标车辆与相机传感器距离保持恒定的情况下 (本次实验设定小目标车辆与相机传感器的恒定距离为 50 m), 以车辆识别图像的对比如作为研究对象, 在不考虑其他干扰条件的情况下, 检测主机所获得的车辆识别图像对比度越高, 就表示小目标车辆检测图像的清晰度越高。小目标车辆检测图像的对比如如图 6 所示。

分析图 6 可知, 随着实验的持续进行, 第 1 组方法检测所得小目标车辆图像的对比如水平不断增大, 直至达到 90%。相较于第 1 组, 第 2 组、第 3 组方法检测所




图 6 小目标车辆检测图像对比度

得小目标车辆图像的对比度水平相对较低，其最大值均未超过 50%。综上可知，若以车辆识别图像的对比度作为研究对象，第 1 组实验方法的可行性更强。

综合上述实验结果来看，在复杂道路交通小目标车辆检测研究中，通过不同方法对小目标车辆与相机传感器距离及图像对比度进行分析。距离方面，基于雷达和视频融合的检测方法（第 1 组）表现突出，小目标车辆与相机传感器距离最大值达 63.6 m，最小值也有 40.1 m，远超对比方法，说明其在远距离检测上更具优势。对比度方面，在 50 m 恒定距离下，第 1 组方法检测所得图像对比度持续增大至 90%，而第 2 组、第 3 组方法对比度最大值均未超过 50%。这表明第 1 组方法不仅能实现更远距离的检测，还能在固定距离下获得更高对比度的清晰图像。综合来看，基于雷达和视频融合的检测方法在复杂道路交通小目标车辆检测中更具可行性与有效性。

测试在不同天气条件、光照强度等复杂环境下，基于雷达和视频融合的复杂道路交通小目标车辆检测方法的误检率。测试结果如表 2 所示。

表 2 不同环境下误检率分析

天气条件	光照强度	误检率/%
晴天	强光	0.013
	正常光	0.025
	弱光	0.044
	夜间	0.057
阴天	强光	0.022
	正常光	0.041
	弱光	0.052
	夜间	0.091

由表 2 可知，在相同天气条件下，随着光照强度的减弱（从强光到夜间），误检率总体呈现上升趋势。这表明光照强度是影响基于雷达和视频融合的复杂道路交通小目标车辆检测方法误检率的关键因素之一。在光照不足的情况下，视频图像的质量会下降，导致视频特征提取的准确性降低，进而影响与雷达特征的融合效果，最终导致误检率增加。但总体来说，所提方法的误检率较低，且未超过 0.1，表明该方法的整

体检测效果较好。

4 结束语

通过上文的研究与实践，提出了基于雷达和视频融合的复杂道路交通小目标车辆检测方法。该方法充分利用了雷达全天候、高测距测速精度的优势，以及视频直观、信息丰富的特点，通过深度融合两种传感器的数据，实现了对复杂道路交通场景下小目标车辆的精准检测。利用有效的坐标转换和融合算法，实现了雷达与视频数据在空间和时间上的对齐；通过 K-means 聚类算法与 YOLOv5 网络提取小目标车辆特征，提高了识别精度和鲁棒性。实验结果表明，该方法确实表现出了优异的检测性能，有效解决了单一传感器在复杂道路交通小目标车辆检测中的局限性。数据增强策略（虽能扩充样本量，但无法完全模拟真实场景中的遮挡、变形等复杂情况，导致模型在极端条件下的泛化能力受限。在未来的研究中，还需建立半自动标注工具，结合仿真数据与少量真实数据迭代优化模型，开发无监督域适应方法，提高检测的鲁棒性。

参考文献：

- [1] 汤林东, 云利军, 罗瑞林, 等. 基于改进 YOLOv5s 的复杂道路交通目标检测算法 [J]. 郑州大学学报 (工学版), 2024, 45 (3): 64-71.
- [2] 江志鹏, 王自全, 张永生, 等. 基于改进 Deformable DETR 的无人机视频流车辆目标检测算法 [J]. 计算机工程与科学, 2024, 46 (1): 91-101.
- [3] 董亮, 王泉兴, 朱磊. 一种融合注意力机制与边缘计算的遥感影像车辆检测算法 [J]. 电讯技术, 2024, 64 (9): 1400-1406.
- [4] 程鑫, 王宏飞, 周经美, 等. 基于体素柱形的激光雷达点云车辆目标检测算法 [J]. 中国公路学报, 2023, 36 (3): 247-260.
- [5] 古佳欣, 陈高华, 张春美. YOLOv8-DEL: 基于改进 YOLOv8n 的实时车辆检测算法研究 [J]. 计算机工程与应用, 2025, 61 (1): 142-152.
- [6] 栗文韬, 徐成伟, 张万鹏, 等. 基于激光雷达+视频的城际铁路周界入侵监测报警技术研究 [J]. 铁道运输与经济, 2023, 45 (7): 134-142.
- [7] 何光辉, 王虹, 方强, 等. 山地坡度自适应星载光子计数激光雷达点云去噪方法 [J]. 红外与毫米波学报, 2023, 42 (2): 250-259.
- [8] 林风泰, 严蘋蘋, 张慧, 等. 基于最近迭代点的毫米波雷达点云数据处理方法 [J]. 信号处理, 2023, 39 (2): 288-297.
- [9] 陶泽宇, 苏建强, 董朝轶, 等. 基于改进密度聚类的三维激光雷达点云滤波算法研究 [J]. 应用激光, 2023, 43 (7): 87-93.

(下转第 64 页)