

分类号: TP242.6

密 级: 公 开

学校代码: 10363

学 号: 2220320172



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目

基于深度学习的障碍物识别

及无人车避障算法研究

论 文 作 者

杨思远

校 内 导 师

王冠凌

校 外 导 师

毛德平

专业学位类别

电子信息 (085400)

研究方向 (领域)

人工智能及系统集成

论文提交日期: 2025 年 5 月 16 日

分类号: TP242.6

单位代码: 10363

密 级: 公 开

学 号:2220320172

题 目 基于深度学习的障碍物识别及无人车避障方法研究

题 目 Research on Deep Learning-Based Obstacle Detection
and Autonomous Vehicle Obstacle Avoidance Methods

学生姓名: _____ 杨思远

校内导师: _____ 王冠凌

校外导师: _____ 毛德平

专 业: _____ 电子信息

研究方向: _____ 人工智能与系统集成

论文答辩日期: 2025 年 5 月 12 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：杨思远

日期：2025 年 5 月 16 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 _____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：

杨思远

指导教师签名：

王冠凌

日期： 2025 年 5 月 16 日

日期： 2025 年 5 月 16 日

基于深度学习的障碍物识别及无人车避障算法研究

摘要

动态避障技术作为无人驾驶导航系统的关键技术挑战，在智慧城市应用场景中具有重要研究价值。本研究针对室内环境下的自主导航问题，以全局环境信息已知条件下的局部动态障碍物规避为研究重点，系统性地开展了基于深度学习的目标识别、全局路径规划与局部实时避障协同控制研究。通过结合深度学习特征提取能力与人工势场法的动态响应机制，提出改进型局部避障算法。本文重点研究动态障碍物识别、全局以及局部路径规划技术，完成算法设计、系统集成与实车验证全流程研究，实验结果表明所构建的避障系统在动态环境下的导航鲁棒性显著提升。本文的主要研究内容如下：

(1) 无人车障碍物识别研究。针对无人车采用的嵌入式平台，对算力、内存资源以及功耗方面都有一定限制，进而导致无人车图像目标检测算法检测速度与精度无法兼顾的问题，在 YOLOv7 的基础上，模型在检测头部分集成了 Dynamic Head 动态头，并在算法主干引入全局注意力机制(global attention mechanism, GAM)和 Slim-Neck 模型结构。最后，引入基于动态非单调聚焦机制的 Wise-IoUv3 损失函数进行参数优化。实验数据表明，经算法改进的 YOLOv7 框架在模型性能上实现显著突破：在保持原有检测效率的基础上，目标识别平均精度较基准模型提升 4.9%。

(2) 无人车路径规划及避障算法研究。深入研究了无人车的路径规划算法，提出了改进全局路径规划与局部路径规划的综合策略，旨在为无人车设计一条既最优又无冲突的全局行驶路径。针对传统人工势场法在局部路径规划中易陷入局部最小值及目标不可达的问

题，对该算法的引力函数进行了优化改进。同时，为了解决概率路线图(Probabilistic Roadmap Method, PRM)算法在全局路径规划中的局限性，引入了伪随机抽样技术和双向随机采样策略来优化采样节点的分布，以此提升路径规划的效率与可靠性。最终运用三次样条插值法对无人车规划路径实施平滑优化，使路径连续性与平滑度显著提升。

(3) 实验验证。为验证改进算法的可行性与稳定性，基于 ROS 机器人操作系统构建实验平台并开展无人车实测实验进行验证。将传感器数据放到 Rviz 中显示，对其进行建图与路径规划实验，将目标检测算法获取的障碍物位置与种类信息送入到路径规划器中，通过改进后路径规划算法于真实场景下进行多次实地实验。实验结果表明，基于深度学习的无人车避障规划算法可在动静态环境中完成自主导航和避障规划任务，验证了本文改进算法的正确性和可行性。

关键词：无人车，深度学习，YOLOv7，路径规划，ROS

Research on obstacle recognition and unmanned vehicle obstacle avoidance algorithm based on deep learning

ABSTRACT

Dynamic obstacle avoidance technology, as a critical challenge in autonomous driving navigation systems, holds significant research value in smart city applications. This study focuses on the issue of autonomous navigation in indoor environments, with an emphasis on local dynamic obstacle avoidance under the condition that global environmental information is known. A systematic investigation is conducted into object recognition based on deep learning, global path planning, and coordinated control of local real-time obstacle avoidance. By integrating the feature extraction capabilities of deep learning with the dynamic response mechanism of the artificial potential field method, an improved local obstacle avoidance algorithm is proposed. This paper primarily focuses on the technologies of dynamic obstacle recognition, global and local path planning, and completes the entire research process from algorithm design, system integration, to real-vehicle validation. Experimental results demonstrate that the constructed obstacle avoidance system exhibits significantly enhanced navigation robustness in dynamic environments. The main research contents of this paper are as follows:

1. Research on Obstacle Recognition for Autonomous Vehicles. Given the embedded platforms used in autonomous vehicles, which have certain limitations in terms of computing power, memory resources, and power consumption, leading to the challenge of balancing detection speed and accuracy in image object detection algorithms, this study proposes

improvements based on YOLOv7. Specifically, the model integrates a Dynamic Head in the detection head section and introduces a global attention mechanism (GAM) and Slim-Neck model structure in the algorithm backbone. Finally, a Wise-IoUv3 loss function based on a dynamic non-monotonic focusing mechanism is introduced for parameter optimization. Experimental data show that the improved YOLOv7 framework achieves significant breakthroughs in model performance: while maintaining the original detection efficiency, the average precision of object recognition is improved by 4.9% compared to the baseline model.

2. Research on Path Planning and Obstacle Avoidance Algorithms for Autonomous Vehicles. This study delves into the path planning algorithms for autonomous vehicles and proposes an integrated strategy that combines improved global path planning with local path planning. The aim is to design an optimal and conflict-free global driving path for autonomous vehicles. To address the issues of traditional artificial potential field methods, such as getting trapped in local minima and target unreachability during local path planning, the attractive and repulsive force functions of the algorithm have been optimized and improved. Meanwhile, to overcome the limitations of the Probabilistic Roadmap Method (PRM) algorithm in global path planning, pseudo-random sampling techniques and bidirectional random sampling strategies have been introduced to optimize the distribution of sampling nodes, thereby enhancing the efficiency and reliability of path planning. Finally, the cubic spline interpolation method is employed to smooth and optimize the planned path of the autonomous vehicle, significantly improving the path's continuity and smoothness.

3. Experimental Validation. To verify the feasibility and stability of the improved algorithm, an experimental platform was constructed based on the Robot Operating System (ROS), and real-vehicle experiments were conducted for validation. Sensor data were displayed in Rviz for mapping

and path planning experiments. The obstacle position and type information obtained by the object detection algorithm were fed into the path planner, and multiple field experiments were carried out in real-world scenarios using the improved path planning algorithm. The experimental results demonstrate that the deep learning-based obstacle avoidance and path planning algorithm for autonomous vehicles can accomplish autonomous navigation and obstacle avoidance planning tasks in both dynamic and static environments, verifying the correctness and feasibility of the improved algorithm proposed in this paper.

KEYWORDS: autonomous vehicle, deep learning, YOLOv7, path planning, ROS

目 录

摘 要	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 课题研究背景及意义.....	1
1.2 国内外研究现状.....	2
1.2.1 无人车目标检测算法研究现状.....	2
1.2.2 无人车避障算法研究现状.....	3
1.3 论文主要研究内容与章节安排.....	5
第 2 章 基于 ROS 的无人车系统结构及算法理论	6
2.1 ROS 系统基础与无人车介绍	6
2.1.1 ROS 操作系统简介	6
2.1.2 ROS 系统架构	7
2.1.3 ROS 环境系统的搭建	9
2.1.4 基于 ROS 的移动无人车	9
2.2 目标检测算法理论基础.....	12
2.3 无人车避障算法理论基础.....	15
2.3.1 人工势场法.....	15
2.3.2 概率路线图方法.....	16
2.4 本章小结	17
第 3 章 基于改进 YOLOv7 的动态目标识别算法.....	17
3.1 YOLOv7 模型优化策略.....	17
3.2 改进的 YOLOv7 模型.....	17
3.2.1 Dynamic Head 目标检测头.....	18
3.2.2 全局注意力机制 GAM	20
3.2.3 Neck 结构改进 Slim 范式.....	22
3.2.4 Wise-IoU 损失函数	23
3.3 实验结果与分析.....	24
3.3.1 训练环境和数据集.....	24

3.3.2 评价指标.....	25
3.3.3 消融实验.....	26
3.3.4 与已有算法的对比实验.....	27
3.4 本章小结.....	28
第 4 章 无人车导航避障算法研究.....	29
4.1 无人车避障算法规划.....	29
4.2 全局路径规划.....	30
4.2.1 改进 PRM 算法	30
4.2.2 改进 PRM 算法仿真实验	35
4.3 局部路径规划.....	38
4.3.1 人工势场法缺点.....	38
4.3.2 改进人工势场法.....	39
4.3.3 深度学习与改进人工势场法结合的避障方法.....	40
4.4 本章结论.....	41
第 5 章 无人车路径规划和避障实验及分析.....	42
5.1 避障算法总体流程与系统运行环境.....	42
5.1.1 避障算法总体流程.....	42
5.1.2 系统运行环境.....	44
5.2 目标检测实验及分析.....	45
5.3 真实环境下无人车实验.....	46
5.3.1 调试设备及实验环境测试.....	46
5.3.2 地图构建测试.....	46
5.3.3 全局路径规划实验及分析.....	48
5.3.4 局部避障实验及分析.....	50
5.4 本章小结.....	54
第 6 章 总结与展望.....	55
6.1 论文的主要工作.....	55
6.2 研究展望.....	55
参考文献	57

攻读学位期间发表的学术论文目录	63
致谢	64

第 1 章 绪论

1.1 课题研究背景及意义

无人车技术作为融合计算机科学、系统工程、信息传感及人工智能等多学科的前沿科技领域，当前正呈现蓬勃发展的态势，并已深度融入人类日常生活。其核心优势在于显著降低人力劳动负荷、提升作业效率，并能有效替代高危环境下的作业任务。该技术体系在商业服务、民生保障、医疗辅助、智能建造、信息通信、现代农业、国防安全及航天探索等诸多应用场景的全面渗透，正持续引发工业领域的广泛关注与战略投入。

在未来的智慧城市生态体系中，无人车将在物资配送、应急通讯保障、环境勘测、消防作业、设备巡检、远程监测及灾后救援等多维度场景中扮演关键角色^[1]。要充分发挥其服务效能，首要前提是构建高效安全的路径规划系统，使机器人能精准抵达目标区域，这项核心技术直接关联到智能体在复杂城市环境中的作业质量。因此，研发具备动态环境感知与实时决策能力的自主导航技术，以及可适应多场景约束条件的智能避障算法，已成为无人车领域必须攻克的首要技术难关，也是实现其规模化应用的核心支撑。

当前，图像处理算法领域的持续技术突破正加速计算机视觉技术体系的革新进程。该技术体系的终极目标在于构建具备类人视觉认知能力的智能系统^[2]，使计算机能够模拟生物视觉机制完成环境感知与语义理解，从而实现以智能载体替代人类视觉进行场景解析与行为决策。

机器视觉的核心优势在于其强大的空间信息获取能力，通过高密度数据采集可精准解析目标对象的几何形态、空间位姿及表面特征等二维空间属性参数，特别在障碍物类型识别、距离估算及高度检测等任务中展现出显著优势，这为移动机器人导航系统的环境建模与路径规划奠定了关键的感知基础。值得注意的是，视觉传感器在动态避障场景中的应用价值尤为突出，其丰富的环境描述能力为实时决策系统提供了关键的空间认知支持。

然而，当前主流视觉算法普遍存在的计算复杂度高、资源消耗大的固有缺

陷，导致实时处理性能难以充分满足机器人系统的动态响应需求。因此，如何在保持算法精度的前提下，通过架构优化与硬件加速实现视觉处理效率的提升，构建兼具环境感知精度与决策实时性的视觉导航框架，成为推进移动机器人智能化发展的关键突破口^[3]，这也是本研究聚焦于视觉辅助动态避障机制创新的根本原因。

本研究聚焦于初始环境信息已知但障碍物位置动态变化的复杂场景。针对传统目标检测算法在移动端实时动态障碍物感知中的局限性，本研究将深度学习领域的先进目标检测框架与无人车避障算法结合。通过优化深度学习模型架构，集成动态检测头与全局注意力机制，实现了对移动障碍物位置和类别信息的高精度实时获取。在局部避障策略中，创新性地将增强型视觉感知模块与改进的人工势场法相结合，通过调整势场函数，显著提升了无人车对突发移动障碍物的响应速度与避障成功率。实验表明，该视觉-避障协同规划框架在动态密集场景下表现出优异的实时避障性能，其研究成果为室内服务机器人、仓储 AGV 等移动平台的自主导航技术提供了兼具理论创新价值与实际工程意义的技术解决方案。

1.2 国内外研究现状

1.2.1 无人车目标检测算法研究现状

目标检测算法的演进可划分为两大技术范式：基于传统手工特征的机器学习方法与基于深度学习的端到端模型。早期研究以特征工程为核心，通过人工设计特征提取器与分类器组合实现目标定位与识别。典型流程包含区域选择、特征提取和分类器训练三个步骤。在特征提取阶段，研究者广泛采用手工设计的特征描述符，如 HOG^[4]（梯度方向直方图）通过统计图像局部区域梯度方向分布来刻画目标轮廓，SIFT^[5]（尺度不变特征变换）则通过多尺度空间极值点提取旋转与缩放不变性特征。然而，这类方法存在显著缺陷：手工特征对目标形变和环境噪声敏感，例如 HOG 难以应对姿态剧烈变化的目标，DPM（可变形部件模型）虽通过部件分解策略提升人体检测稳定性，但其逐类建模机制导致泛化能力受限。此外，滑动窗口遍历策略带来的计算冗余使得传统算法难以满足实时性需求，如 DPM 在 VOC 竞赛中虽取得突破^[6]，但推理速度仅约 0.07FPS，

无法应用于动态场景。

2012 年 AlexNet^[7]在 ImageNet 竞赛中的突破标志着深度学习时代的到来，目标检测技术随之发生革命性转变。以 R-CNN^[8]系列为代表的两阶段检测器率先实现技术突破：R-CNN 通过选择性搜索生成约 2000 个候选区域，利用 CNN 提取特征后采用 SVM^[9]分类，但存在重复计算特征导致的效率低下问题。Fast R-CNN^[10]通过引入 ROI 池化层实现特征共享，将检测速度提升至 0.5FPS，而 Faster R-CNN 进一步通过区域建议网络（RPN）实现端到端训练，将速度提高至 5FPS。这类算法在 PASCAL VOC 数据集上达到 74%以上的 mAP，但两阶段架构的固有复杂性仍限制其实时性。

2015 年，J. Redmon 团队研发了 YOLO(You Only Look Once)^[11]框架，其识别速率显著超越两阶段目标检测算法。研究团队随后迭代开发的 V2^[12]和 V3^[13-14]版本，在维持实时性优势的前提下提高了检测精度。至 2020 年，A. Bochkovskiy 等人在 YOLOv1-v3 基础上推出了 YOLOv4^[15]版本，创新性地构建 CSPDarkNet53 特征提取网络，结合空间金字塔池化模块（SPP）优化多尺度特征融合，并运用金字塔注意力网络（PAN）增强目标定位能力。在训练策略方面，采用 Mosaic 等数据增强技术拓展样本多样性，因此其检测精度和检测速度再度提高一个层次。2022 年提出的 YOLOv7 通过架构创新实现性能飞跃：采用扩展高效层聚合网络（ELAN）增强梯度传播效率，引入动态标签分配策略优化正样本匹配，并设计重参数化模块（RepConv）提升推理速度。实验表明，YOLOv7 在 640×640 分辨率下以 30ms/帧的速度达到 56.8% mAP，较 YOLOv5^[16]提升 3.2 个百分点，成为首个在精度和速度上全面超越两阶段检测器的单阶段模型。鉴于 YOLOv7 模型兼具高精度与高效性，故本文采用该目标检测网络研究移动障碍物的识别与检测。

1.2.2 无人车避障算法研究现状

无人车应用中，避障功能占据着举足轻重的地位。在行驶过程中，无人车需持续监测周边环境，依托其搭载的传感器系统，实时获取关于工作环境与自身状态的信息，并据此灵活调整行进策略。这一过程的目的是确保能够规划出一条既可行又安全的路径，从起始点顺利抵达目标点。因此，对于无人车而言，有效的避障规划是其实现各类应用的前提和基础。无人车避障路径规划算法可

分为传统避障和智能避障，前者包括向量场直方图^[17]、人工势场法^[18]和动态窗口法^[19]等，后者涵盖模糊逻辑算法和机器学习算法等。最早的经典避障方法是单元分解法，基本思想是在自由区域与存在障碍物区域之间进行隔离，并为自由区域建立邻接图，但这种方法难以快速找到最优路径^[20]。这些方法虽各具优势和特性，但在实际应用中仍面临局部最优解、规避失效及目标不可达等缺陷。针对此类问题，国内外学者已开展深入研究并取得显著进展。Mao 等^[21]提出一种改进遗传算法机器人避障方法，提高了机器人控制性能。Zhang 等^[22]提出一种移动机器人离散时间预测轨迹跟踪控制的避障方法，同时考虑轨迹跟踪和避障控制率有效性。陈纪廷等^[23]提出一种改进时间弹性带方法，将基于噪声的密度聚类算法引入地图转换，使得障碍物约束部分计算量减小。然而，上述方法主要基于静态环境设计，一旦应用于动态环境，其有效性可能会受到影响甚至失效。

人工势场法的理论基石是构建虚拟能量空间模型，其核心在于将车辆运动环境等效为连续可导的势能函数场。在该理论框架中，目标点被定义为势能最低区域，形成对无人车的“吸引力场”；障碍物则对应势能峰值区域，产生“排斥力场”，这样的势能差异会形成一股吸引力^[24]，引导车辆向目标点移动，同时障碍物产生的排斥力^[25]则将车辆推离障碍。然而，该方法并非没有缺点，最突出的问题是它有时会导致车辆陷入局部最小值^[26]，或在面对复杂环境时出现路径规划失败的情况。在特定空间配置下，当目标点与障碍物的空间分布存在特定几何关系时，可能导致规划系统陷入局部势能极小值，进而引发路径不可达的计算困境。对于这些问题，学者们已经开发出了多项解决方法，例如引入路径平滑技术，或者与其他路径规划方法如 A* 或 RRT^[27]结合，以规避局部最小值。

当前，无人车避障感知研究的主流方案集中于视觉传感器、激光雷达及毫米波雷达三类设备。其中深度相机凭借更强的抗干扰能力、更低廉的成本、更便捷的部署方式及更广泛的应用场景优势，相较激光雷达展现出显著优势。在机器人环境认知领域，视觉感知技术^[28]作为最接近人类认知模式的解决方案，正成为该领域的研究热点。吴亚辉等^[29]采用视觉方法进行环境感知并利用人工势场法进行避障决策。李娟等^[30]提出一种以 STM32F1 处理器为核心的视觉避障控制系统。当前，在动态复杂场景中，障碍物规避系统仍存在实时响应效率与

决策可靠性方面的技术挑战。这一研究方向通过优化时变环境下的多约束决策模型，有望突破传统避障算法的性能瓶颈，为构建安全高效的智能交互系统提供理论支撑与技术保障。

1.3 论文主要研究内容与章节安排

本研究针对室内动态场景，在已知全局地图但局部环境未知的情况下，探索基于视觉的障碍物避障方法。通过深度学习模型实时检测障碍物位置与类别，结合改进人工势场避障算法设计，最终在实际无人车上完成算法部署与验证，为室内无人车导航提供了可行解决方案。全文共六章，各章节主要内容有如下：

第一章 绪论。阐述综述了国内外目标检测及避障算法的研究进展，明确了本文核心研究内容以及整体的组织架构。

第二章 基于 ROS 的无人车系统结构及算法理论介绍。介绍了 ROS 操作系统、如何搭建 ROS 环境系统以及实验所需的基于 ROS 操作系统的无人车实物，最后介绍了无人车避障算法理论基础。

第三章 基于改进 YOLOv7 的动态目标识别算法。详细介绍本研究中如何改进 YOLOv7 算法使其精度提高、计算量减小，将 YOLOv7 基础模型部分融入注意力模块以及注意力机制，在模型头部引入 Slim 范式结构，有效减少计算复杂度与资源占用。预测阶段采用 WiSe-IoUv3 损失函数优化检测精度，并通过实验验证改进算法的有效性，最终提升了 YOLOv7 模型的有效性与实用性。

第四章 无人车导航避障算法研究。针对不同场景下的无人车路径规划问题，本文提出了改进人工势场法与概率路线图（PRM）算法，系统阐述了算法的优化实现机制，并生成平滑行驶轨迹。通过仿真实验与实车测试验证了改进算法的有效性及鲁棒性。

第五章 无人车路径规划和避障实验及分析。依次阐述基于深度学习的避障算法框架及系统部署环境，在实际环境下对改进的目标检测算法进行验证，最终通过多场景实验验证全局路径规划与基于视觉的无人车局部避障算法，并完成结果分析。

第六章 总结与展望。总结本研究的主要成果和贡献，分析研究中存在的不足之处和未来可能的研究方向。

第 2 章 基于 ROS 的无人车系统结构及算法理论

2.1 ROS 系统基础与无人车介绍

2.1.1 ROS 操作系统简介

机器人操作系统(ROS, Robot Operating System)^[31-34]是一个机器人软件平台,它能够给用户提供一个全面的操作系统环境,是一个分布式处理系统,每个进程相对独立。基于模块化组装思想,该框架将高频复用的代码单元、工具链及基础软件封装为标准化功能组件。在开发过程中,开发者可根据具体需求灵活调用预置功能模块,这种组件化开发模式显著提升了系统构建效率与可操作性。作为分布式计算框架,ROS 体系集成了硬件抽象层、设备驱动库及通用算法模块,通过提供开源软件包与通信中间件,实现了节点间的服务调用与消息传递。特别是在多传感器协同工作场景中,该操作系统通过定义跨节点通信协议和数据融合机制,有效攻克了异构数据源实时交互的技术瓶颈,为复杂机器人系统的集成开发提供了可靠保障。相较于传统计算架构,ROS 在代码复用效率方面未呈现突破性提升,其编程语言体系也保持常规特性。然而该框架的创新性体现在采用解耦式节点通信机制,这种分布式架构设计与机器人系统开发需求高度契合。通过点对点拓扑结构的通信协议,ROS 构建了跨主机的协同计算网络,有效分担了运算负载,显著提升了跨平台系统集成效率。各功能节点既支持同机部署,也可通过局域网或广域网实现分布式配置,这种灵活的部署方式突破了物理硬件的限制。值得注意的是,ROS 的分布式通信特性不仅激发了研究者对机器人软件架构的创新探索,其多语言支持特性(包括 C++、Python 等)更降低了开发门槛,为异构机器人系统的研发提供了技术范式。

ROS 凭借其网络通信架构与模块化设计理念,正成为机器人开发领域的首选框架。其核心机制中,主节点通过中央协调机制管理各子节点通信,并支持网络参数的动态配置服务;同时,系统通过封装复杂功能至标准库,使驱动模块与算法组件仅需少量适配即可实现跨框架兼容,进而达成轻量化部署与高效集成。ROS 构建了基于编译系统和组件化架构的开源工具链,提供涵盖运动控制、感知算法等模块的标准化开发工具集。这种模块化的设计范式显著降低了

二次开发门槛，使开发者能够高效实现功能扩展与系统定制。随着功能包的持续迭代，该机器人操作系统已演化出完善的仿真验证体系，开发者可通过 Gazebo 仿真引擎构建高保真虚拟场景，对机器人导航算法进行预研验证，有效提升了复杂环境适应能力。值得关注的是，基于 ROS 框架的轮式移动机器人 SLAM 算法研究，不仅构建了精确的环境感知模型，更为无人驾驶系统提供了鲁棒的定位解决方案，其技术成果在物流运输、服务机器人等应用场景中展现出显著的工程价值。

2.1.2 ROS 系统架构

ROS 采用三层架构设计模型，其技术实现包含通信层、文件管理层与开源协作层三个维度，如图 2-1 所示。其中，开源协作层作为技术生态的核心支撑，构建了去中心化的开发者社区网络。该层级通过创建开放式代码托管平台，不仅实现了算法模块的分布式存储与版本控制，更促进了全球开发者群体的知识共享和技术协作。这种社区驱动的创新模式，形成了独特的代码协作机制与知识传播体系，为 ROS 的持续演进提供了源源不断的动力。




图 2-1 ROS 架构

文件系统层构建了 ROS 程序模块的层级化存储体系，其核心机制在于通过模块化目录结构对代码资产进行分类管理。该层级遵循功能解耦原则，将运动控制、传感器驱动、消息定义等程序组件分别存储于对应目录，形成了清晰的代码治理框架。这种结构化管理模式不仅提升了代码可维护性，更为大型机器人项目的协同开发提供了标准化文件组织方案，体现了 ROS 在代码工程管理领域的创新实践。这包括消息格式的定义、服务接口的规范、功能包的组织架构以及清单描述文件等关键要素。功能包作为 ROS 系统的基本构建单元，通过模块化设计封装了最小结构单元与核心功能组件，整合了节点执行代码、控制脚本、环境配置文件等必要元素，形成了高效且可复用的开发模块。功能包列表

揭示了不同功能包与语言类型之间的关联。

在计算图层级，ROS 构建了基于自治型功能单元的消息传递框架。该层级的核心在于建立分布式计算拓扑，通过网络传输实现进程间通信。在此过程中，系统衍生出消息、话题、服务三类核心要素：其中消息载体封装了结构化数据，话题作为异步通信通道实现消息广播，服务机制则提供同步请求-响应式交互接口。作为最小可执行单元，节点封装了特定算法或服务，通过发布-订阅模式或客户端-服务端模式进行信息交互，其运行状态可通过可视化监控界面实时观测。开发者通过编排多个节点构建网状计算图，本质上是对分布式任务流进行编程实现，这种开发范式显著提升了复杂机器人系统的构建效率

在 ROS 计算图框架中，消息被定义为遵循特定序列化格式的二进制数据流，作为节点间信息传递的有效载荷。消息体依据预定义协议进行编码，既包含传感器原始数据，也可封装控制指令等结构化信息，是构建分布式计算图的基础元素。话题通信机制借鉴了传统中间件的数据总线概念，节点通过发布-订阅模式向特定话题发送或接收数据，这种异步通信模式为机器人状态估计、环境建模等任务提供了实时数据通道。相较于消息机制，服务通信采用同步的请求-响应范式，遵循客户端-服务端架构，能够实现复杂计算任务的远程过程调用。这种分层级的通信体系，既保证了实时性要求，又为异构系统间的信息交互提供了标准化解决方案。




图 2-2 ROS 的计算图结构

机器人软件开发本质上是针对功能节点的编程实现，其核心在于构建分布式计算拓扑中的消息路由机制。消息体被定义为遵循特定编码规范的数据载体，既包含传感器原始数据，也可封装控制指令等结构化信息，作为节点间进程通信的有效载荷。话题机制借鉴了传统中间件的数据总线概念，通过发布-订阅模式实现多节点间的异步信息交换，这种通信架构为机器人状态估计、环境建模

等任务提供了实时数据通道。开发者通过编排消息类型、定义话题接口、配置服务节点，实质上是构建分布式系统的消息流拓扑，这种开发范式显著提升了复杂机器人系统的构建效率。

2.1.3 ROS 环境系统的搭建

基于 ROS 的机器人的开发包括机器人和工作台。ROS 开源生态提供了丰富的预制功能组件库，这些模块化软件包通过包管理系统实现即插即用，涵盖了感知驱动、算法实现和工具链等核心领域。开发者既可通过命令行工具完成系统级功能组件的全局部署，也可将源码克隆至本地工作区执行定制化构建流程。当需要深度定制时，开发者可采用工作区隔离机制，对特定组件源码进行修改后重新编译，此时本地工作区的定制版本将覆盖系统默认组件。对于需要彻底移除系统级组件的情况，可通过包管理命令完成卸载操作，随后在隔离工作区中重建修改后的组件版本，这种源码级定制能力为机器人系统的个性化开发提供了灵活解决方案。

2.1.4 基于 ROS 的移动无人车

无人车搭载必备的传感器、开发环境和 SLAM 导航软件套。如图 2-3 所示是本次实验使用的无人车，其中包括：主控制器：昇腾 310 系列 AI 处理器、主控 MCU、电调、电机、IMU、激光雷达、里程计记录器、摄像头、操作系统：ROS_humble、编程语言：Python3.8。使用的激光雷达具有 360 度全方位扫描、10 赫兹自适应扫描频率、激光测距每秒 5000 次、测量距离 25 米、激光安全标准 Claass1、测量量程解析度 0.1%、A6 核 ARM64 位处理器、主频 2GHz、内存 2G。



图 2-3 移动无人车

摄像头所使用的是 Intel RealSense D435i 深度相机，如图 2-4 所示。它是一款集成深度感知、RGB 图像采集和惯性测量单元的多功能相机，专为需要高精

度三维空间感知和动态运动追踪的应用场景设计。其核心特性与技术参数如下：

(1) 深度传感器

分辨最高支持 1280×720 ；帧率：30fps，适配动态场景；深度范围：0.1 米至 10 米，支持短距精细检测与长距大场景扫描；技术原理：采用主动红外立体视觉，通过红外激光散斑投射与双摄像头三角测量实现深度计算。

(2) RGB 摄像头

分辨率最高 1920×1080 ；视野 (FOV)： $69.4^\circ \times 42.5^\circ$ ，匹配深度传感器视野，便于数据对齐。

(3) 惯性测量单元

集成六轴传感器（加速度计+陀螺仪），提供实时姿态估计与运动追踪数据，增强 SLAM 和动态场景稳定性。



图 2-4 Intel RealSense D435i 深度相机

下位机系统采用硬件-软件协同架构，如图 2-5 所示。STM32 微控制器作为主控单元，与电机驱动模块及光电编码器共同集成在控制基板中，通过 USB 数据接口实现与机器人操作系统的双向通信协议。该系统接收上位机传输的运动控制指令，经主控芯片解析后驱动电机，通过车轮转动实现车辆位姿的精准控制。该设计将控制算法硬件化部署，有效提升了系统执行效率。

无人平台底盘的运动控制性能取决于传感器系统与主控单元的协同配合，其关键性能参数指标详见表格 2-1。作为无人车的“智慧中枢”，上位机系统由主控模块与导航算法模块构成，通过 USB 通信接口与下位机控制单元建立数据传输通道，并搭载 ROS 机器人操作系统作为软件框架。该架构实现了环境感知、决策规划与运动控制的分层处理，其中上位机负责全局路径规划与任务调度，下位机执行具体的运动指令，二者通过标准化通信协议实现数据交互。




图 2-5 下位机

表 2-1 无人车底盘参数

性能	参数
最大线速度	4m/s
最大角速度	180°/s
电机功率	2400W
工作电压	12V
电调额定电流	120A

无人车自主导航技术是一个综合体系，它深度融合了运动控制技术和SLAM（即时定位与地图构建）等多个关键方面。这些技术相互依存，共同推进无人车自主导航能力的进步，如图2-6所示。在无人车自主导航的过程中，运动控制技术起到了至关重要的作用。它包括轨迹规划和轨迹跟踪两个细化层面。在机器人运动控制体系中，轨迹规划模块与轨迹跟踪控制器构成了层级递进的技术架构。轨迹规划作为路径生成的后处理环节，通过集成运动学约束条件和动力学模型，将几何路径转化为时间参数化的运动指令序列，为下游控制模块提供可执行轨迹。轨迹跟踪控制器则承担指令解析与执行功能，其通过实时补偿系统误差，将规划轨迹转换为执行器控制信号，最终形成闭环控制结构。这种分层架构实现了从路径生成到执行器指令的完整映射，其中轨迹规划侧重运动学约束优化，轨迹跟踪强调动力学补偿控制，二者协同作用形成了完整的运动控制闭环。目前，流行的运动控制算法包括模型预测控制、比例-积分-微分控制以及强化学习等。与此同时，SLAM 技术是无人车实现自主导航的基础。它使无人车能够在未知环境中，通过不断观测到的环境特征来构建地图，并同时确定自身在地图中的位置。SLAM 技术为无人车提供了必要的空间感知能力，

是实现自主导航不可或缺的一环。




图 2-6 导航技术组成

2.2 目标检测算法理论基础

鉴于当前在复杂环境下目标的准确检测仍然存在技术难题，深入研究目标检测技术显得尤为重要。在目标检测算法评价中，精度和速度是两个关键指标。近些年来，基于深度学习网络结构提出了一系列优秀算法，涵盖了从单阶段到两阶段，从单尺度网络到多尺度金字塔网络的多种形式。

YOLO 算法作为单阶段目标检测算法中的经典模型，以其在深度神经网络基础上进行快速的对象检测和定位能力而著称，特别适配于需要即时反应的系统。相较于传统两阶段检测范式，该算法采用端到端的一阶段检测架构，将检测任务转化为回归问题，通过单一深度神经网络同步预测边界框坐标与类别置信度。尽管在检测精度上存在一定妥协，但其推理速度获得质的飞跃，这一特性使其在行人检测等实时性要求较高的场景中展现出显著优势。YOLO 算法通过卷积网络把输入视频帧分割为 $N \times N$ 个相同尺寸的网格单元，并在每个网格单元中生成 B 个预测框，以便进行目标检测。最终检测网络的输出大小为 $N \times N \times (B \times (4+1) + C)$ 。相较于其他目标检测方法，YOLO 算法具有较快的检测速度，因为它通过卷积神经网络直接在整个图像上进行预测，而不需要生成大量的候选区域建议。然而，对于小尺度的目标，特别是小尺度的行人目标，YOLO 算法可能会出现检测精度较低的情况，因为在小目标上的定位准确性可能会有所不足，导致错过或错误检测的情况发生。随后，YOLOv2 在 2017 年推出，通过

采用更深的网络架构、批量归一化等技术，提出特征提取网络 Darknet-19，增强目标深层特征的获取，改善了检测精度。然而，YOLOv2 在效率与精度平衡上仍存局限，尤其对遮挡物体及小尺寸目标的检测表现欠佳，具备较大优化空间。次年推出的 YOLOv3 针对上述问题进行了算法升级，进一步提升了检测精度与推理速度。YOLOv3 通过引入多尺度预测和特征金字塔网络等技术，提高了对不同尺度目标的检测能力，同时保持了较高的速度和精度。另外，YOLOv4 在 2020 年推出，引入了一系列创新技术，包括 CSPDarknet53、Mish 激活函数、SPP-Net 等，使算法在精度与速度维度均获显著提升。YOLOv5 继承 YOLOv4 架构并优化模型结构，同时引入多项创新技术。YOLOv5 的模型结构更加轻量化，使用了跨阶段部分网络和路径聚合网络等模块来提升检测性能。这些模块帮助改进了检测性能，提高了模型的效率和准确性。其中跨阶段模块通过特征图双通道划分策略有效削减计算量，路径聚合模块则通过多尺度特征融合机制增强检测性能，共同提升了模型效率与检测精度。同时，YOLOv5 引入了自动模型缩放、超参数优化和模型蒸馏等技术，使得模型更易于训练和部署，并在多个数据集上取得了优秀的检测结果。尽管 YOLOv4 和 YOLOv5 在性能方面有所提高，但在处理大规模数据集或复杂场景时，仍可能面临性能瓶颈。YOLOv7^[35]是由 Alexey Bochkovskiy 团队在 2022 年提出的网络模型框架。YOLOv7 在识别精确度和处理速度上均超越了前代 YOLO 模型，进一步推动了目标检测技术的发展。

YOLOv7 通过整合 E-ELAN 注意力网络、基于级联模型的模型缩放^[36]策略以及卷积神经网络重参数化等先进方法，实现了在较低的计算成本下显著提升目标检测的精度。YOLOv7 网络架构包括三个关键部分：输入端（Input）、主干网络（Backbone）、和头部（Head）。输入端负责将输入图像调整至统一的尺寸，然后传递至主干网络进行初始特征的提取过程。随后，头部将主干网络输出的三层特征综合起来，并对路标进行精确定位，最终输出目标的边界框坐标。如图 2-7 所示。




图 2-7 YOLOv7 网络结构图

主干网络部分构建自一个系列的 CBS 模块、ELAN 卷积层以及 MP 模块。CBS 模块结合了卷积层、批量归一化 (BN) 以及 LeakyReLU 激活函数, 旨在捕捉图像的多尺度特征; ELAN-H 模块对高效远程注意力网络 (ELAN)^[37]进行了扩展, 通过扩大、交错和融合不同分组, 进一步增强了网络对复杂模式的学习效果, 且无损于初始梯度的传导; MP 模块在 CBS 架构基础上引入双分支特征降维结构: 上层分支通过 MaxPooling 操作压缩特征图空间维度, 配合卷积层削减通道数; 下层分支采用重复卷积操作, 同步实现通道数减半与特征图下采样, 形成多尺度特征融合机制。最终, 这两个分支通过连接操作 (Cat) 合并, 产生了规格减半、通道数量保持一致的结果特征图。

头部框架采用路径聚合特征金字塔网络 (PAFPN)^[38], 该设计通过自底向上的路径促使底层细致信息顺畅传达至高层, 实现多尺度特征的有效结合。包含在 PAFPN 内的 SPPCSPC 模块通过多样的池化层和 CBS 模块的结合, 实现了不同尺度特征图的规格统一, 从而有效捕获了更全面的上下文信息。该模块利用一种创新的分流连接方式将来自上一层的特征图细分后, 将其分别传递到下一层的两个不同分支中。此种设计策略有效削减了模型结构的复杂性, 并且增强了训练过程的效率。在这一架构上, 检测头部进一步引用 REP (RepVGG Block)^[39]结构, 用于调整从 PAFPN 产生的不同尺寸特征层 P3、P4、P5 的通道数量, 接着利用 1×1 卷积层对提取的特征进行处理, 以便进行道路标志的置信度评估、类别分类以及锚框位置^[40]预测。

2.3 无人车避障算法理论基础

2.3.1 人工势场法

人工势场法作为一种局部路径规划策略，其核心原理是将机器人运动环境建模为虚拟势能场，其中目标点构建吸引力场引导机器人趋近，障碍物生成排斥力场防止碰撞。通过合成空间各点的引力与斥力矢量，形成控制机器人向目标点运动的合力场。




图 2-8 人工势场法原理图

人工势场由引力势场与斥力势场协同构建，设势场函数为 U ，在点 q 处势场合力记为 U_q ，则有：

$$U_q = U_{att}(q) + U_{rep}(q) \quad (2-1)$$

其中， $U_{att}(q)$ 表示 q 点的引力场函数， $U_{rep}(q)$ 表示斥力场函数。引力场函数通常定义为公式(2-2)：

$$U_{att}(q) = \frac{1}{2} \xi \rho^2(q, q_{goal}) \quad (2-2)$$

式中： ξ 表示尺度因子， $\rho(q, q_{goal})$ 表示当前点 q 到目标点 q_{goal} 之间的距离。

斥力场函数通常定义为公式(2-3)：

$$U_{rep}(q) = \begin{cases} \frac{1}{2} \eta \left(\frac{1}{\rho(q, q_{obs})} - \frac{1}{\rho_0} \right)^2, & \rho(q, q_{obs}) \leq \rho_0 \\ 0, & \rho(q, q_{obs}) > \rho_0 \end{cases} \quad (2-3)$$

式中：斥力增益系数 η 用于调节障碍物的排斥强度， $\rho(q, q_{obs})$ 表示当前点 q 距离最近障碍物的距离， ρ_0 表示障碍物的影响半径，作为障碍物影响半径，当 q 与障碍物间距超过该阈值时，对应的斥力场失效。

在人工势场模型中，引力场与斥力场的合力通过势场函数的梯度进行表示。假设 q 点的势场函数的值 U 为该点的能量，那么该点的梯度 ∇U 就能看作该点的

力向量，引力场和斥力场中的虚拟力就可以表示为如下两式(2-4)(2-5)：

$$F_{\text{att}} = -\nabla U_{\text{att}}(q) \quad (2-4)$$

$$F_{\text{rep}} = -\nabla U_{\text{rep}}(q) \quad (2-5)$$

基于势场函数与势场力的数学关系分析，势场中任意点处的梯度方向代表了该点势函数值的最大增长方向。基于这一特性，梯度下降法被引入人工势场框架中，作为路径规划的核心优化策略。该方法通过驱动无人车从起始位置沿势场负梯度方向进行迭代运动，逐步逼近势能全局极小值点，直至势场梯度收敛至零点，此时无人车即到达理论上的平衡点或目标点。

人工势场法对控制和传感误差有一定的鲁棒性,但是其缺陷同样明显，当环境中某点的引力和斥力的强度相等、方向相反时，作用在机器人上的合外力将趋近于零，导致无人车会陷入局部最优解，进而无法达到目标点。

2.3.2 概率路线图方法

概率路线图方法由美国莱斯大学的学者 P. Svestka 和 L. E. Kavraki^[41]提出，其核心思想基于场景地图中自由空间与障碍区域的分布特征，构建概率路径网络图的方法^[42]。该算法通过随机采样策略将连续空间离散化，继而运用启发式搜索算法在离散化空间内高效探寻可行路径，即使采用相对稀疏的采样点分布仍能保证路径存在性。研究表明，对于多数应用场景，有限数量的采样点即可覆盖主要可达空间，并大概率生成有效路径。采样规模及空间分布特性对算法完备性具有直接影响，随着采样密度提升，路径网络覆盖度随之增强，算法完备性将渐进优化。

PRM 算法的核心思想是通过概率图模型表征机器人运行环境自由空间，基于随机采样生成节点构建图结构，并采用局部路径规划算法连接相邻节点形成路径网络，最终通过图搜索算法获取可行路径解。PRM 算法通过离线学习阶段和查询阶段来完成^[43]。在离线学习阶段，在构型空间内随机采样生成 N 个有效节点，构建节点间连通性并剔除与障碍物有接触的节点线^[44]。生成无向路径网络图 $G=(E,V)$ 。其中， V 表示为节点集， E 表示为可行边集。查询阶段基于路径网络图信息、起始位姿和目标位姿，采用启发式搜索算法获取有效路径^[45]。

基于采样的路径规划方法可分为单次查询型与全局预计算型两类。单次查询型方法从指定初始位形出发，通过局部路径网络构建，在构型空间内动态扩

展树形结构以建立连通性；全局预计算型方法则预先构建完整路径网络，综合采样数据与碰撞检测结果生成无向图模型，完整表征构型空间拓扑连通性，最后通过图搜索获得具有可行性的路径^[46]。

2.4 本章小结

本章首先介绍本文所使用的 ROS 机器人与操作系统，包括 ROS 机器人架构以及对 ROS 机器人软件操作系统。其次介绍了基于几种深度学习的目标检测算法理论；最后介绍了本文所使用的无人车避障算法的理论基础，为下文的改进算法奠定基础。

第 3 章 基于改进 YOLOv7 的动态目标识别算法

3.1 YOLOv7 模型优化策略

利用计算机视觉和深度学习技术在动态障碍物检测方面取得了成就，这些基于计算机视觉和人工智能（AI）的方法，包括静态与动态的纹理分析^[47]、卷积神经网络（CNN）^[48]和 360 度传感器技术^[49]，已被广泛应用于目标检测。传统的 YOLOv7 算法已经不能支撑对目标的精准识别。针对这个问题，本研究在 YOLOv7 中嵌入 DyHead 动态注意力模块和 GAM 全局注意力机制，通过调整多头全局注意力机制，在特征层级对尺寸的警觉性、在空间定位上的敏感性以及在输出通道的任务识别能力之间实现协同作用，显著增强了目标检测头的表示能力。在模型头部设计中，采用 Slim 范式进行轻量化改进。预测模块引入 WiSe-IoUv3 损失函数，针对多尺度目标检测特性进行优化，有效改善小目标及密集目标的检测效果，使模型在保持高效推理的同时实现更精准的预测输出。

3.2 改进的 YOLOv7 模型

针对传统识别网络在检测中存在的问题，例如检测精度不高、模型参数量以及计算量过大等问题，针对上述提到的问题进行了三个方面的创新改进：

（1）为了让模型更加专注于动态目标的检测，本文融合了多重注意力机制的 Dynamic Head 目标检测头与 GAM 全局注意力模块。

（2）为了降低模型的参数量和计算成本，本文在特征提取网络中采用了 Slim-Neck 结构来替换原模型的 PAFPN 结构。

（3）为了增强网络模型在边界框回归方面的性能，本文采用 Wise-IoUv3 作为新的损失函数。

本研究提出了一种基于改进的 YOLOv7 的检测识别模型。该模型的结构如图 3-1 所示，上述改进有助于提高检测的效率和准确率，展示了本研究在动态目标识别领域的应用潜力。

典型实现路径包含通过查询向量（Query）、键向量（Key）和值向量（Value）的投影运算构建权重参数。最终输出的特征表示 $W(F)$ 经自注意力机制调制后，仍保持与原始输入特征 F 完全一致的维度结构，从而保证网络层间的特征兼容性。

最简单的方法是采用全连接层构建注意力函数，但直接在所有维度上学习会导致计算量庞大且维度过高，因此这种做法通常不切实际。于是转而把注意力功能分解为三个单独的、序列化的注意力过程，其中每个过程分别只针对一个特定的维度进行专注：

$$W(F) = \pi_c(\pi_s(\pi_z(F) \cdot F) \cdot F) \cdot F \quad (3-2)$$

Scale-aware Attention π_L ：首先引入尺度感知注意力机制来整合不同尺度的特征，根据它们的语义重要性进行选择融合：

$$\pi_L(F) \cdot F = \sigma \left(f \left(\frac{1}{SC} \sum_{s,c} F \right) \right) \cdot F \quad (3-3)$$

其中， $f(\cdot)$ 为线性函数，采用 1×1 卷积近似， $\sigma(x)$ 为 hard-sigmoid 激活函数。

Spatial-aware Attention π_s ：为增强模型对空间特征的识别，我们引入了位置感知注意力模块，并针对其高维特性，采用分解策略来简化计算，降低复杂度。首先利用形变卷积（deformable convolution）对注意力学习过程进行稀疏化处理，以简化学习过程，接着执行跨尺度的特征整合：

$$\pi_s(F) \cdot F = \frac{1}{L} \sum_{l=1}^L \sum_{k=1}^K w_{l,k} \cdot F(l; p_k + \Delta_k; c) \cdot \Delta m_k \quad (3-4)$$

Task-aware Attention π_c ：为了加强联合学习及目标特征表达的泛化性，开发了一种任务感知型注意力模块。这种设计旨在优化模型对不同任务要求的响应能力，以提升模型整体的性能表现。该模块可以动态开关特征通道以辅助不同任务：

$$\pi_c(F) \cdot F = \max(\alpha^1(F) \cdot F_c + \beta^1(F), \alpha^2(F) \cdot F_c + \beta^2(F)) \quad (3-5)$$

其中， $[\alpha^1 \ \alpha^2 \ \beta^1 \ \beta^2]^T = \theta(\cdot)$ 为超参数，用于控制激活阈值，而 $\theta(\cdot)$ 类似于 DyReLU。

最终，我们采取串行方式应用上述集成的注意力机制，该机制可进行多层堆叠，以增强效果。Dynamic Head 的配置示意图如图 3-2 所示。




图 3-2 Dynamic Head 配置示意图

3.2.2 全局注意力机制 GAM

GAM 模块^[50]旨在从外部环境检查图像中复杂背景提取突出特征。通过融合 GAM 模块，YOLOv7 算法得以有效提取背景中的关键信息，进而显著提升了整体的目标检测性能。

为了提升图像分类任务中的模型性能，2018 年引入了 Squeeze-and-Excitation Network（SE-Net）^[51]，利用通道注意力和通道级特征融合来抑制不重要的通道。然而，SE-Net 的一个缺点是忽略了空间维度。为了解决这一限制，随后引入了卷积块注意力模块（CBAM）^[52]和瓶颈注意力模块（BAM）进行了改进。然而，CBAM 和 BAM 仍然未能考虑通道空间交互，导致跨维度信息的丢失。为了解决这个问题，开发了三重注意力模块（TAM）^[53]，通过通道、空间宽度和空间高度这三个维度并将注意力权重引入每两个纬度之间，保留了更多的特征信息。即便如此，TAM 仍然不能全部覆盖三个维度，也只能在两个维度才有效果。为了增强跨维度交互，我们提出了一种能够捕获跨所有三个尺寸重要特征的注意力机制。

考虑到数据集复杂的上下文与多重干扰，全局注意力机制（GAM）作为抑制图像中不重要信息的最佳选择。与其他注意力模块相比，GAM 在降低信息损失和增强全局维度交互特征的能力两方面更有优势。GAM 在 CBAM 基础上优化了子模块结构，但保留了通道-空间注意力的串行机制。其通道注意力子模块采用三维排列方式，确保通道、高度和宽度三个维度的信息完整保留。整个过程如图 3-3 所示。




图 3-3 GAM 注意力机制模块

提出的注意力机制作用于特征 $F \in R^{C \times H \times W}$ ，其中 C 代表通道数， H 表示高度， W 代表宽度。中间状态 F_2 和输出 F_3 的定义如式(3-6)和式(3-7)定义：

$$F_2 = M_c(F_1) \otimes F_1 \quad (3-6)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (3-7)$$

在此公式中， M_c 代表通道注意力图， M_s 代表空间注意力图，符号 $\otimes$ 表示逐元素相乘。

在第一步中，通道注意力图 M_c 被应用于 F_1 ，结果产生一个通道维度的注意力表示。然后，这个注意力图与 F_1 进行逐元素乘法，产生中间状态 F_2 。在第二步中，空间注意力图 M_s 被应用于 F_2 ，捕捉中间状态内的空间依赖关系。空间注意力图与 F_2 进行逐元素乘法，产生最终输出 F_3 。融合了通道与空间两种注意力机制的提出的注意力策略，旨在识别并强调输入特征图中沿着通道、高度和宽度这三个维度的关键特征。

GAM 的通道与空间注意力子模块结构分别如图 3-4 和图 3-5 所示。通道注意力模块用三维特征保持和 MLP 增进通道与空间信息交互，空间注意子模块则以双层卷积细化空间信息处理。同时，考虑到最大池化操作可能会引起的信息损失，该操作已被移除，以便更好地保留特征映射中的信息。




图 3-4 通道注意力子模块示意图




图 3-5 空间注意力子模块示意图

3.2.3 Neck 结构改进 Slim 范式

(1) GSConv 模块

基于深度学习的目标检测算法大致分为两种：单步法（single-shot）检测和双步法（two-stage）检测。双步法检测算法根据稀疏检测原理能够获得较高的平均精度均值（mean Average Precision, mAP），但检测速度偏慢。相比之下，单步法检测速度比双步法更快，但在小目标检测和定位的能力不如双步法，在对实时性有高要求的场景下，单步法比双步法更适用。为应对当前模型高计算成本的挑战，采纳了轻量化模型设计，主要策略是采用深度可分离卷积（DSC）来降低模型参数数量和浮点运算次数（FLOPs）。尽管如此，由于 DSC 在处理输入图像时，将其通道信息进行了隔离，使它在特征抽取和合成的效能显著不如标准卷积（SC），这种差距可能会削弱目标检测的精确度。为了使 DSC 的输出效果尽量接近 SC，Li^[54]等人提出一种名为 GSConv 的新方法，其采用密集卷积操作来增强信息的整合。

在卷积神经网络（Convolutional Neural Network, CNN）中，在图像传递通过卷积神经网络的各层时，它会逐渐经历从空间信息到通道信息的转变。在这个转变过程中，特征图的空间维度往往会减小，同时通道的数量增加，这种转变通常会使一部分语义信息损失。密集卷积计算能够在最大程度上保持通道间的内在联系，相反，在稀疏卷积过程中，这些通道之间的联系则完全被切断。GSConv 的设计旨在最大程度上保持这些通道间的链接。如果 GSConv 被使用在模型的每个阶段，将会加深网络的层次，进而影响模型的推理速度。特别的，在特征金字塔网络的 Neck 部分，特征图的通道维度通常处于最大状态，而宽度和高度维度最小，此时特征图的尺寸已不需再次变化。因此，GSConv 在 Neck 部分中使用通常能获得最理想的效果。

(2) Slim-Neck 结构

首先将标准卷积替换为 GSConv，采取这种方式，能够将计算成本降低至约标准卷积的 50%到 60%，而且模型的学习能力仍然能够接近于使用标准卷积的情况。此外，GSConv 还拓展了设计，引入了 GS bottleneck 模块，如图 3-6(a)所示。

同时，本研究提出单次聚合型跨层模块 VoV-GSCSP，通过一体化特征融合

机制在降低计算复杂度的同时，维持了高精度特征表达能力。此模块的结构布局如图 3-6(b)所示。值得一提的是，如果在 Neck 部分使用 VoV-GSCSP 来替换由标准卷积构成的 CSP 层，将使得整体模型在浮点运算次数上相较于后者显著减少。




图 3-6 VoV-GSCSP 模块。(a) GSbottleneck 模块; (b) VoV-GSCSP 模块

3.2.4 Wise-IoU 损失函数

在目标检测领域，损失函数的设计直接决定检测精度，其核心是通过量化预测框与真实标注的空间偏差来优化定位结果。因此引入了 Wise-IoU 作为一种创新的损失函数，旨在平衡模型训练过程中不同画质图像的影响，进而提升检测的精确度。通过在 IoU 基础上加入类别权重演变为 Wise-IoU，目标是最小化不同类别间的差异，并削弱这些差异可能对测试结果产生的负面影响。通过为各个类别赋予特定的权重，这些权重在计算 IoU 时被应用于不同类别预测框的重叠部分，以此来实现加权处理。对不同类别预测框的重叠部分进行加权，以此提高评估的准确性。Wise-IoUv1、Wise-IoUv2、Wise-IoUv3 是 Wise-IoU 的三种版本。Wise-IoUv1 引入了一种基于距离度量的双重注意力机制，有效地解决了低质量数据集在模型训练过程中可能引发的问题。公式如 (3-8) (3-9)：

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (3-8)$$

$$R_{WIoU} = \exp \left[\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right] \quad (3-9)$$

其中，上标*代表将宽 W_g 与高 H_g 的梯度从计算图中分离出来，这样做能够有效提升模型收敛的效率。同时，在预测框与真实标注框重合度较高时，减少对中

心点距离的敏感度，增强了模型对于不同样本的泛化能力。

Wise-IoUv2 在 Wise-IoUv1 的基础上，吸取了 Focal Loss 的设计思想，引入了单调聚焦系数 λ ($\lambda > 0$)，从而有效地降低了简单样本对损失函数的贡献，专注于更难识别的样本。引导模型更多地关注难分样本，进而提升了模型的分类表现，公式如下：

$$L_{WIoUv2} = \left(\frac{L_{IoU}^*}{L_{IoU}} \right)^{\lambda} \cdot L_{WIoUv1} \quad (3-10)$$

在 Wise-IoUv1 的基础上，Wise-IoUv3 引入了离群度 β 参数，用于构造非单调聚焦系数 r ，这一设计用于进一步区分训练样本的难易程度，从而更细致地调整模型对不同样本的关注度，公式如下：

$$r = \frac{\beta}{\delta \cdot \alpha^{\beta-\delta}} \quad (3-11)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (3-12)$$

$$L_{WIoUv3} = r \cdot L_{WIoUv1} \quad (3-13)$$

在 Wise-IoUv3 算法框架中，离群度系数 β 作为评估预测框质量的量化指标，通过滑动窗口机制持续更新的 IoU 损失均值（记为 $\overline{L_{IoU}}$ ）进行自适应调节。该动态调节机制能够维持 β 值在合理区间，有效缓解了模型训练后期的收敛停滞现象。超参数 α 与 β 共同构成梯度优化策略的核心参数，当预测框的离群度达到预设阈值 C 时，对应梯度权重达到最大值。得益于 $\overline{L_{IoU}}$ 的实时更新特性，锚框质量评估标准随训练进程动态演化，使得梯度增益分配策略能够自适应训练状态。该算法特别强化了对中等质量锚框的优化关注，通过梯度资源的合理分配，显著提升了目标定位任务的精度表现。本文将会使用 Wise-IoUv3 替代 YOLOv7 原模型的损失函数。

3.3 实验结果与分析

3.3.1 训练环境和数据集

为了验证改进后算法的有效性，本文在收集大量动态图像上进行仿真实验。因此，研究通过 COCO(Common Objects in COntext)、PASCLA VOC2007(Pattern Analysis, Statistical Modelling and Computational Learning Visual Object Classes

2007)以及手动拍摄，人、猫、狗多种类型的常见动态障碍物图像，共计得到 6200 张图像，并将其并入本文的数据集中以进行扩充。在实验中，依照 8:2 的比例将这些数据划分为训练集与测试集，部分图片样本如图 3-7 所示。同时本文算法的构建与改进所使用的深度学习环境如表 3-1 所示。

表 3-1 实验环境

参数	配置
操作系统	Wimdows11
CPU	AMD Radeon(TM)Graphics
显卡	NVIDIA GeForce RTX3060 Laptop GPU
库达环境	CUDA11.6
Python 环境	Python 3.8.10
学习框架	Pytorch



图 3-7 常见动态目标数据集

3.3.2 评价指标

为评价所建立模型的性能，实验选取该领域通用的评估标准，评估指标如式所示：

$$P = \frac{TP}{TP + FP} \quad (3-14)$$

$$R = \frac{TP}{TP + FN} \quad (3-15)$$

$$AP = \frac{1}{101} \sum_{R \in [0, 0.01, \dots, 0.99, 1]} P_i(R) \quad (3-16)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (3-17)$$

在式中： TP 指的是实际为正例且被模型正确预测为正例的样本数量。 FP 指的实际为负例但被模型错误预测为正例的样本数量。 FN 指的是实际为正例但被模型错误预测为负例的样本数量。 P 代表预测为正例中实际为正例的比例。 R 代表实际为正例中被正确预测为正例的比例。 AP 代表在各个召回率水平上精确率的平均值。 mAP 代表在所有类别上 AP 的平均值，是综合评价检测模型性能的重要指标。

3.3.3 消融实验

为验证改进 YOLOv7 算法的有效性，本研究对原算法进行了模块化的改进，逐一添加各个模块，并在相同数据集上进行测试。通过消融实验的方式，评估了各个改进模块的影响，有关实验结果详见表 3-2 和图 3-8 所示。消融实验能够准确理解每个模块对模型整体性能的贡献，并据此验证算法改进的实效性。

YOLOv7_model 1 表示在原 YOLOv7 算法基础上集成了 Dynamic Head 目标检测头的模型；YOLOv7_model 2 在 YOLOv7_model 1 的基础上进一步融合了全局注意力机制模块（GAM）；YOLOv7_model 3 则在 YOLOv7_model 2 上引入了 Slim-Neck 模型结构；最后，YOLOv7_model 4 在 YOLOv7_model 3 的基础上采用了 Wise-IoUv3 损失函数。此系列消融实验的设置旨在全面定性与定量分析各项改进措施，以展现最终改进模型的优越性能。

表 3-2 的数据显示，在引入 Dynamic Head 目标检测头之后，YOLOv7_model 1 相较于原 YOLOv7 模型在精度、召回率以及 $mAP@0.5$ 分别提升了 1.8%、0.8% 和 0.5%，验证了 Dynamic Head 在特征信息保留及小目标识别能力上的优势，尽管其计算量略增 1.1%。进一步比较 YOLOv7_model 1 与 YOLOv7_model 2，引入 GAM 后，模型在上述三项指标上分别有了 1.7%、0.8% 和 1.1% 的提升，但计算量也相应的增加了 0.8%。在 YOLOv7_model 2 与 YOLOv7_model 3 的对比中，得益于 Slim-Neck 的引入，在计算量下降了 2.1% 的同时， $mAP@0.5$ 也从 76.5% 提升至 77.2%，其中精度和召回率分别提升了 0.9% 和 1.4%。Wise-IoUv3 通过优化不同质量图像的训练结果，使得 YOLOv7_model 4 在精度、召回率、 $mAP@0.5$ 方面相对 YOLOv7_model 3 分别提升 1.6%、2.1% 和 2.6%，计算量则只微增 0.2%。整体而言，改进后的 YOLOv7 模型在精度上提高了 6.2%，召回率和 $mAP@0.5$ 则分别提升了 5.1% 和 4.9%，在计算效率方面也实现了 0.1% 的降

低。综上所述，该改进 YOLOv7 模型在提高检测性能的同时，也确保了计算效率。

表 3-2 消融实验结果

算法名称	DyHead	GAM	SlimNeck	Wise-IouV3	Precision	Recall	mAP@0.5 (%)	GFLOP/s
YOLOv7(baseline)	*	*	*	*	75.1	77.5	74.9	10.4
YOLOv7_model 1	√	*	*	*	76.9	78.3	75.4	11.5
YOLOv7_model 2	√	√	*	*	78.6	79.1	76.5	12.3
YOLOv7_model 3	√	√	√	*	79.7	80.5	77.2	10.1
YOLOv7_model 4	√	√	√	√	81.3	82.6	79.8	10.3

下文展示了来自数据集上的改进 YOLOv7 模型的一些具有代表性的检测结果，如图 3-8 所示。相比于原版 YOLOv7 算法，在确保目标检测准确性的前提下，改进模型显著提高了对目标的检测能力的置信度。这一结果充分证明了对 YOLOv7 算法所做改进的有效性。



图 3-8 改进前后结果对比

3.3.4 与已有算法的对比实验

为了进一步探究改进后模型的检测能力，本研究在相同的环境下，对比 Faster-RCNN^[55]、Swin-transformer^[56]、YOLOv7 以及改进后的算法在相同数据集上的实验结果。实验中设置输入图像大小为 640×640，并进行 150 轮训练。在综合评估模型性能时，选用精度（Precision）、召回率（Recall）和平均精度（mAP@0.5）作为关键评测指标。如表 3-3 所示，改进的 YOLOv7 算法在 mAP@0.5 指标上取得了最高值，达到 71.1%，显著领先于 Faster-RCNN 算法模型的 55.6%的 mAP@0.5。同时，YOLOv7 算法也优于传统的目标检测算法，其

mAP@0.5 达到 65.8%，但与本文提出的改进算法仍有差距。在精确率和召回率方面，本研究提出的改进算法也表现最佳，分别达到 72.4%和 72.6%。此项实验结果明确表明，改进后的 YOLOv7 算法在多个评价指标上均优于对比的其他目标检测算法，充分证明了本改进算法的有效性和实用性。

表 3-3 与已有算法对比实验

模型	Precision/%	Recall/%	mAP@0.5/%
Faster-RCNN	61.4	60.5	55.6
Swin-transformer	63.1	63.7	58.4
YOLOv7	70.6	69.7	65.8
Improved YOLOv7	72.4	72.6	71.1

3.4 本章小结

在多场景实时目标检测中，传统算法容易受到环境和空间限制的影响，这可能导致检测精度的下降，为了解决这些问题，提出了一种基于 YOLOv7 的改进模型。根据改进后的模型可得到以下结论：

（1）该模型融合了 DyHead 目标检测头显著提升了在不同环境中对目标的识别。

（2）在网络的主干部分引入 GAM 注意力机制模块，提升了从外部环境检查图像中复杂背景提取突出特征，从而提高检测精度。

（3）改进后的模型也融合了 Slim-Neck 模型结构，但在保持了足够精度的同时也降低了计算和网络结构的复杂性。

（4）采用 Wise-IoUv3 损失函数替代原模型结构中的损失函数，加速了网络结构的收敛和检测速度。

通过对数据集的训练实验展示了本文算法在维持高准确率和召回率的同时，有效的检测出图像中的目标。更为关键的是，在 mAP@0.5 指标上，该模型不仅超越了 YOLOv7 模型结构，而且还优于其他的大部分检测模型，为下文结合动态障碍物局部避障提供了目标检测算法的基础。

第4章 无人车导航避障算法研究

近年来,随着科技的发展,无人车已广泛应用于工业、医疗、农业等相关领域^[57-59]。路径规划作为自动驾驶车辆实现自主导航的核心环节,需基于路径短、高效率、无碰撞等指标,在复杂环境中生成从起点到终点的全局最优路径或可行次优解,且该路径能够规避沿途的障碍物^[60]。常用的移动机器人路径规划算法有A*算法^[61]、概率路线图法(Probabilistic Roadmaps Method, PRM)^[62]、快速探索随机树(RRT)算法^[63]、人工势场法(Artificial Potential Field, APF)^[64-65]、蚁群算法^[66],每种算法都有其优劣之处。下文将介绍对无人车全局路径规划、局部路径规划及结合深度学习的无人车避障算法的研究。

4.1 无人车避障算法规划

在机器人执行路径规划任务时,全局与局部规划策略是至关重要的。全局路径规划旨在探寻整体上的最优路径,为机器人的行进提供宏观指导;而局部路径规划则侧重于在局部区域内寻找最优解,以确保机器人能够实时避开障碍物。

针对无人车路径规划中人工势场法的局部最小值、目标不可达等问题,PRM 路径规划算法以其高效、灵活、快速查询和广泛适用性成为复杂环境中路径规划的有效方法。因此本文提出了改进概率路线图法与人工势场法的路径规划算法。

首先,对局部路径规划人工势场法的引力函数进行优化,使得无人车离目标点较远时,受到的引力应有所减少,然后针对概率路线图搜索效率不高且路径转折频繁的问题,提出了一种创新的全局路径规划算法,该算法以主轴为基准进行双向约束采样。通过约束主轴采样角度范围并引入双向交替扩展策略,优化节点连接机制以减少无效路径探索,在保持全局搜索能力的同时显著提升路径规划效率。此外,该算法结合了三次样条插值。这将增加路径规划的平滑性,保证无人车能够更平稳、安全地实现路径规划任务。仿真实验证明,优化后的算法能显著提升收敛速度并增强路径的平滑性。最终,我们将这一改进算

法成功应用于无人车的实际导航测试中。实验结果表明，在路径质量和计算时间上，改进的路径规划策略比传统的人工势场法和 PRM 具有更好的性能。

4.2 全局路径规划

4.2.1 改进 PRM 算法

(1) 伪随机抽样

在离线学习阶段，传统的 PRM 通过全局均匀采样策略生成空间节点，继而构建全连通路网络建模。在 PRM 的整个过程中，离线学习阶段耗时占极小比例。因此，本研究设计了一种主轴导向的双向约束采样机制，通过限制采样角度范围并采用交替扩展策略，有效削减无效路径探索，显著提升实时路径规划性能。

在 PRM 算法框架中，传统随机采样策略生成的节点规模随规划空间维度扩展呈线性增长，难以保证全局均匀分布特性，导致采样点分布呈现局部聚集特征并产生冗余数据。最短可行路径以较高概率分布于起始点与目标点连线的邻近区域，该几何特征被明确建模为聚焦采样区域，定义为空间主轴通道。

为了构建空间主轴信息，我们将起点的坐标设置为 $S(x_s, y_s)$ ，目标点的坐标设置为 $G(x_g, y_g)$ 。空间主轴的长度 L 和偏角 θ 表示为：

$$L = \|G - S\|_2 \quad (4-1)$$

$$\theta = \frac{\pi}{2} - \arctan \frac{|y_g - y_s|}{|x_g - x_s|} \quad (4-2)$$

本章设计了一条长度为 L 空间主轴并规划了 n 个采样点进行布局，得到采样间隔 N_d ，如下所示：

$$N_d = \frac{L}{n} \quad (4-3)$$

参考随机抽样的原理，我们在空间主轴附近的扇形区域内进行了采样点的对称分布，采样点 $P_{i,j}(x, y)$ 计算如下：

$$x = x_s + r_d \times \cos(\theta + \phi_j) \quad (4-4)$$

$$y = y_s + r_d \times \sin(\theta + \phi_j) \quad (4-5)$$

$$r_d = i \times N_d, i = [1, 2, \dots, n] \quad (4-6)$$

其中 (x_s, y_s) 表示无人车的起始点； r_d 表示采样半径；采样半径以起点为中心；

$\phi_j \in [-\phi_m, \phi_m]$ 表示采样点偏转的角度； ϕ_m 表示最大偏转角。采样区域的角度参数被用于调控采样点的空间分布特性，在横向平面内，采样点以主轴为对称轴呈镜像对称分布。 ϕ_m 决定了采样区域在主轴垂直方向上的覆盖范围。通过这种角度调控机制，采样点的空间分布密度和方向特性得到有效控制，为后续的特征提取和模式识别提供了规范化的数据基础。随着 ϕ_m 的增大，采样点会沿着主空间轴向各个方向更加广泛地分布。采样点沿主轴各向扩展，形成全域覆盖，为实现均匀分布，设计动态调整策略。并使用 $\Delta\phi = \phi_m/n$ 以增量调整采样范围。调整后采样点的分布如图 4-1 所示。




图 4-1 调整后采样点

综合均匀采样特性，计算了自由空间内采样点 p 的数量，并定义了一个关键指标——水平采样层的有效采样率 R ：

$$R = \frac{p}{N} \quad (4-7)$$

在分层采样的框架下，设定当前采样层的样本总数为 N ，并将有效采样率 R 作为衡量该采样层空间连通性的直接量化指标。当 R 取值过低时，表明该层采样点分布失效，大量节点陷入障碍区域，导致路径搜索效率下降。若采样层边界保持固定离散化步长，将显著增加障碍物空间采样概率。为此，引入自适应随机增量 Δr 构建动态步长调整机制，通过概率分布优化实现障碍规避与空间覆盖的平衡。该机制使采样间隔随局部环境复杂度动态伸缩，在维持采样密度均匀性的同时，有效降低障碍物区域无效采样概率。如图 4-1(d) 所示，通过调整随机增量 Δr 的值来获得了图 4-2 中的采样分布。具体来说，当随机增量 Δr 的数值增大时，采样点的分布趋势趋向于更加随机；相反，当 Δr 的数值减小时，采样点的分布则趋向于更加均匀。

如图 4-3 所示，可以清晰地看到空心标记代表的是基准均匀采样点，而实心标记代表了经过自适应调整后得到的优化采样点。红色标记特别指出了那些因陷入障碍区域而无效的采样点，而黑色标记则标示了位于自由空间内的有效采

样点。这样的可视化帮助我们直观地理解了采样点的分布情况以及优化调整的效果。针对初始有效采样率较低的问题，通过引入动态半径波动率调节机制，结合伪随机采样策略对后续采样层进行优化。该机制通过概率化调整采样间隔，使采样点分布呈现非均匀自适应特性，在保持全局覆盖能力的同时，有效规避障碍密集区域，将有效采样率提升至 0.8。利用伪随机采样策略，有效地规避了障碍物，从而显著提升了采样点的生成质量。




图 4-2 基于伪随机的抽样方法：(a) $\Delta r = r$, (b) $\Delta r = 0.5r$, (c) $\Delta r = 0.25r$




图 4-3 采样点调整示意图

(2) 双向随机采样

双向 PRM 的本质是在生成采样图之后，采取双向搜索策略：一方面从起始节点出发进行前向搜索，另一方面则从目标节点开始进行反向搜索。双路径搜索算法通过中间节点的路径融合机制，在交汇节点形成全局最优路径。这种路径融合机制在强化路径鲁棒性的同时，实现了搜索效率的优化，其通过动态剪枝策略有效避免了路径衔接阶段的冗余计算开销。相较于传统单路径搜索方法，该算法在保持路径安全性的前提下，显著降低了路径规划的时间复杂度，展现出更高的计算资源利用率。然而，在无人车的真实路径规划中，有时可能会出现两条彼此独立的路径，一条起始于起点并终止于非目标点，另一条则从目标点反向起始并结束于起点的附近区域，但这并非路径规划的理想结果。在这个过程中，这两种路径可能无法满足。

因此，为了解决上述问题，本研究提出双向交替扩展策略：前向搜索从起

点向目标推进，反向搜索从终点逆向扩展，当反向搜索捕获有效节点时，前向搜索重启并形成交替迭代机制。该双向协同机制通过动态调整搜索方向，加速路径连通性验证过程，在保持全局探索能力的同时显著提升路径搜索效率。这样，找到了中间的重叠节点，然后寻求最优路径。

PRM 的改进显著加快了路径搜索效率。如图 4-4 所示，栅格化地图上标有黑色障碍物、起始节点(s)和目标节点(g)。为了清晰展示，正搜索路径用实线标出，而负搜索路径则用虚线表示。首先确定主轴 L 以及采样点偏转角度，同时双向 PRM 在正方向上搜索采样点，然后开始搜索下一个采样点。同时搜索四个采样点 a_1 、 a_2 、 a_3 和 a_4 。如果路径 (s,a_1) (s,a_2) (s,a_3) 和 (s,a_4) 均符合搜索路径规则，因此被视为有效路径，并被保存在路径集 F，如图 4-4(a)所示。然后，可行采样点为 b_1 、 b_2 、 b_3 和 b_4 反向。同样，如果路径 (g,b_1) ， (g,b_2) ， (g,b_3) 和 (g,b_4) 也满足搜索路径规则，那么这些路径也会被添加到路径集 F 中，如图 4-4(b)所示。然后继续切换前向搜索并找到节点 c_1 、 c_2 、 c_3 等。确定 (s,c_1) ， (s,c_2) ， (s,c_3) 和 (s,c_4) 等是否满足路径集要求。相应的路径存储在路径集 F 中，如图 4-4(c)和(d)所示。如果找到中间的重叠节点 d，前向 PRM 找出重叠位置以及反向 PRM，这意味着双向 PRM 找到一个完整的路径。如图 4-4(e)和(f)所示。




图 4-4 正负交替搜索法

(3) 三次样条曲线的路径生成

PRM 显著提高了路径搜索效率。然而，拐点仍然太多，这显然是算法中的一个缺点。因此，本文采用三次样条插值方法使路径更加平滑，三次样条插值通过一系列三次多类型分段插值形成平滑曲线。用三次样条插值方法对无人车

的路径线进行拟合，使路径的线段更加平滑，同时保证了无人车的高效率，避免了移动时突然停止或突然转弯引起的硬件损坏。

集合 $[a, b]$ 具有相同的插值节点， $a = x_0 < x_1 < \dots < x_n = b$ ，对应于三次样条函数 $f(x)$ 。如果函数值满足以下两个条件，则 $f(x)$ 称为三次样条插值函数。 $f(x)$ 的要求仅在每个子区间 $[x_{i-1}, \dots, x_i]$ ($i=1,2,\dots,n$)中并确定三次多项式，设置为：

$$f(x_0) = y_0, \dots, f(x_{n+1}) = y_{n+1} \quad (4-8)$$

$$f_-(x_i) = f_+(x_i) = y_i, i = 1, 2, 3, \dots, n, \quad (4-9)$$

$$f'_-(x_i) = f'_+(x_i) = y_i, i = 1, 2, 3, \dots, n, \quad (4-10)$$

$$f''_-(x_i) = f''_+(x_i) = y_i, i = 1, 2, 3, \dots, n. \quad (4-11)$$

从上面的定义来看，三次多项式 $f(x)$ 有 $4n+4$ 个待定系数，因为 $[a, b]$ 上有 $n+1$ 个单元，每个区间有 4 个待定系数。因此，必须需要 $4n+4$ 个插值条件来确定三次多项式 $f(x)$ ，由式(4-8)可以看出有 $n+2$ 个插值条件。根据等式 (4-9)， $f(x)$ 在插值节点处是连续的，有 n 个条件。等式(4-10)和(4-11)表示 $f(x)$ 的一阶和二阶导数在插值节点处是连续的，插值条件为 $2n$ 。根据前文，加上两次边界条件的设定，共有 $4n+2$ 个插值条件需要被满足。然而，需要两个边界条件来处理三次样条插值函数。常用的边界条件如下：

(1)自然边界条件。两个端点的二阶导数为零，即：

$$f''(x_0) = f''(x_n) = 0 \quad (4-12)$$

(2)钳边界条件。指定第一个和最后一个节点的一阶导数，即：

$$f'_0(x_0) = A, f'_{n-1}(x_n) = B \quad (4-13)$$

(3)非扭曲边界条件。第一节点上样条的三阶导数与第二节点相同。最后的三阶导数三阶导数节点也等于它在倒数第二个节点上，即：

$$f_0'''(x_0) = f_1'''(x_1), f_{n-2}'''(x_{n-2}) = f_{n-1}'''(x_{n-1}) \quad (4-14)$$

在改进 PRM 算法搜索的最优路径上，根据随机路径节点的位置进行插值算法。样条插值在搜索的节点集中分布插值。具体算法过程如下：

(1)存储关键节点。我们算法的第一步是构建一个txt文件，该文件用于存储路径中的每个拐点，即关键节点。以文件的形式存储这些关键节点，以促进样条插值算法的后期过程。

(2)预设采样点。linspace 函数用于生成线性间距向量，N 点生成 x_1 和 x_2 之间的点行向量。N 表示两个采样点之间的采样点数。在本文中，采样点在开始时

设置为 50。然后，采样点分别设置为 100 和 150。根据获得的不同数据信息和仿真结果，将确认 PRM 算法和双向 PRM 算法的最佳组合。

(3)通过分析函数方程，保证 $f(x)$ 样条插值得到三次多项式 $y=f(x)$ 。三次多项式将以近似的方式测量离散数据断点 (x,y) 。根据定理，已知两点之间只能确定一条线。然而，三次多项式不限于一。因此，在本文中，应用非扭曲边界条件来获得三次多项式的精确表达式。三次样条插值方法用于求解函数 $y=f(x)$ 在给定插值点 x 处的值，该函数由向量 x 和对应的 y 值定义。通过匹配矩阵的每一列与 x ，我们可以得到一系列插值点上的函数值，进而构建出插值函数值矩阵。

(4)设置返回值。返回值是由向量 x 和 y 确定的分段三次样条多项式的系数矩阵。这个系数矩阵将用于后续的计算中，以便在需要时执行三次样条插值并绘制出相应的函数曲线。

4.2.2 改进 PRM 算法仿真实验

在本文中，采用 AMD Radeon(TM)Graphics 处理器的计算机、NVIDIA GeForce RTX3060 的显卡和 16GB 的内存大小进行仿真实验，以验证改进人工势场法及 PRM 融合算法和三次样条平滑曲线的有效性。操作系统为 Windows 11，仿真平台为 MatlabR2024a。分别模拟了采用三次样条插值的算法 1、算法 2、算法 3 的实验结果。通过采用多样化的网格图进行仿真测试，能够确保障碍物位置的变化能够产生可供比较的实验数据结果，从而使实验结果更具说服力。算法 1、算法 2、算法 3 分别代表：未改进的 PRM 算法；改进的 PRM 算法；结合三次样条插值的改进的 PRM 算法。




图 4-5 地图 1 中三种算法实验结果比较




图 4-6 地图 2 中三种算法实验结果比较

在本文中，选择了三种不同的地图环境进行仿真实验，如图 4-5、图 4-6、图 4-7 所示，其中地图大小为 500×500 。坐标(10, 490)为移动机器人的起始节点，坐标(490, 10)为目标节点。黑色部分是障碍物部分，白色部分是移动机器人的自由动作区域。折线是没有三次样条插值融合的路径图。曲线是引入三次样条插值的路径图，采样点 $N=100$ 。上述仿真结果表明，三种算法的搜索时间和路径长度不同。通过大量仿真实验，统计三种算法的时间与路径长度数据，取均值作为评价指标。具体数据如表 4-1 表 4-2 所示：




图 4-7 地图 3 的三种算法实验结果比较

表 4-1.不同地图的平均搜索时间比较

地图模型	平均搜索时间/s		
	算法 1	算法 2	算法 3
地图 1	2.24	1.98	2.05
地图 2	1.74	1.58	1.61
地图 3	1.76	1.67	1.73

表 4-2.不同地图的平均搜索时间比较

地图模型	平均最优路径长度		
	算法 1	算法 2	算法 3
地图 1	1082	1051	1059
地图 2	925	874	880
地图 3	715	698	703

搜索时间设置为算法的运行时间，可以用 MATLAB 中的时间函数确定。将路径长度单元设置为地图大小单元步长。如表 4-1 所示，算法 2、算法 3 在平均搜索方面与算法 1 进行了比较。数据显示，与算法 1 相比，算法 2 的平均搜索时间缩短了 11.6%、9.2%和 5.1%，最短路径优化提高了 3%、5.3%和 3%。这表明 PRM 算法的改进在路径长度上并不明显，但搜索效率大大提高。地图 2 中 9.2%的时间优化结果和 5.3%的路径优化结果表明，随着地图复杂度的增加，算法 2 具有更明显的效果。在表 4-2 中，算法 3 在最短路径长度方面与算法 1 进行了比较。同样，与传统的 PRM 算法相比，三次样条双向融合算法提高了平均搜索时间和最短路径长度。从图 4-5 到图 4-7，平均搜索时间减少了 8.5%、7.5%和 1.7%，最短路径优化 2.1%、4.9%和 1.7%。尽管具有三次样条的双向融合算法不可避免地丢失了一定的搜索时间，但与传统的 PRM 算法相比，它有明显的改进，如图 4-5(c)、4-6(c)和 4-7(c)所示。平滑优化使破碎的路线更加平滑，使无人车行走更安全、更稳定。

表 4-3 不同 N 值的实验结果比较

N 的大小	路径搜索时间/s	路径长度
50	2.78	713
100	3.02	699
150	4.77	697

采样点 N 的值对算法的搜索效率至关重要。目前，该参数的设置基本上是由实验数据和经验值决定的。在本章中，N 的值分别设置为 50、100 和 150，以获得改进的算法路径查找时间和路径长度的实验数据，从而确定 N 的最佳值。具体实验数据如表 4-3 所示。在表 4-3 中，路径长度随着 N 的增加而增加，但由于搜索过程的计算量的增加，相应的搜索时间也会增加。在选择合适的 N 后，可以清楚地看到原始破碎线路径是平滑的，平滑曲线有助于移动机器人的路径

行走。在本章中，大量的实验数据显示，当 $N=100$ 时，本章所提出的改进算法在搜寻最优路径时展现出了最高的效率。简而言之，与传统算法相比，改进后的算法不仅收敛速度更快，而且在路径规划上的效率也更为优秀。更重要的是，该算法所生成的路径质量也达到了最优水平。在引入三次样条插值方法后，对路径进行平滑处理，使无人车的实际行走更加稳定更安全。为了进一步验证本文改进算法的性能，与其他路径规划算法在测试地图 1、2、3 中分别测试 50 次，以平均路径长度和平均运行时间为评价指标进行测试。路径规划结果如下：

表 4-4 改进算法与其他路径规划在测试地图下的对比结果

地图模型	本文改进算法		A*算法		DWA 算法	
	路径长度/m	运行时间/s	路径长度/m	运行时间/s	路径长度/m	运行时间/s
地图 1	1059	2.05	1070	2.10	1068	2.12
地图 2	880	1.61	894	1.78	889	1.82
地图 3	703	1.73	722	1.81	719	1.86

从表中可以看出：改进 PRM 算法在路径规划中的优势主要体现在高效性上，它不仅能在复杂环境中快速生成路径，而且相比 A*算法和 DWA 算法，其运行时间更短，同时保持路径长度的合理性，从而在实时性和计算效率上展现出显著优势。

4.3 局部路径规划

4.3.1 人工势场法缺点

在无人车路径规划领域，人工势场法凭借计算效率高、路径平滑的优势被广泛采用，但其固有缺陷亦不容忽视，总结如下：

(1)局部最小值问题。在复杂障碍环境中，人工势场法易形成局部势阱：当无人策划进入凹形障碍区域时，斥力与引力平衡导致合力消失，使系统陷入震荡或停滞状态，无法生成有效路径

(2)目标不可达问题。在传统人工势场模型中，通常默认目标点邻域为自由空间，因此当无人车接近目标时，斥力分量可忽略，仅受引力驱动直达目标。然而实际场景中目标点周围常存在障碍物，导致在最终逼近阶段斥力可能超过引力，使合力方向偏离目标点，造成目标不可达的路径失效问题。

4.3.2 改进人工势场法

为了解决上述问题，引力过大可以通过修改引力函数进行优化，使得无人车离目标点较远时，受到的引力应有所减少，减少的幅度也应与距离有关。引力场改进公式如下：

$$U_{att}(q) = \begin{cases} \frac{1}{2}K_{att}(q - q_g)^2, & (q - q_g) \leq d \\ dK_{att}(q - q_g) - \frac{1}{2}K_{att}d^2, & (q - q_g) > d \end{cases} \quad (4-14)$$

其中， K_{att} 为引力尺度因子， q 为机器人的位置， q_g 为目标点的位置， d 为某一特定距离，在本文中成为距离因子。

对应的引力为：

$$F_{att}(q) = -\nabla U_{att}(q) = \begin{cases} K_{att}(q_g - q), & (q - q_g) \leq d \\ -dK_{att} \frac{q - q_g}{\|q - q_g\|}, & (q - q_g) > d \end{cases} \quad (4-15)$$

在传统人工势场模型中，目标不可达与局部极小值问题源于势场耦合机制的固有缺陷：当移动机器人抵达目标点时，引力场强度衰减至零，但障碍物斥力场仍可能残留，导致合力方向偏离目标点，形成目标不可达现象；而当障碍物斥力合力与引力方向共线且未达目标点时，系统可能陷入引力-斥力平衡状态，产生局部极小值陷阱。为此在障碍物斥力场模型中加入调节因子 $\rho^n(q, q_{goal})$ ，该机制通过距离耦合动态调节斥力场强度，确保仅在目标位置实现势场同步归零，有效消除局部极小值及目标不可达问题。

同时对本文的斥力场公式做如下修改：

$$U_{rep}(q) = \begin{cases} \frac{1}{2}\eta\left(\frac{1}{\rho(q, q_{obs})} - \frac{1}{\rho_0}\right)^2 \rho^n(q, q_{goal}), & \rho(q, q_{obs}) \leq \rho_0 \\ 0, & \rho(q, q_{obs}) > \rho_0 \end{cases} \quad (4-16)$$

其中 n 为正数， q_{goal} 为目标点位置， q_{obs} 为障碍物位置。

标点的距离，式中 n 为任意常数，经多次仿真实验得 $n=2$ 。

$$F_{rep}(q) = -\nabla U_{rep}(q) = \begin{cases} a_1\eta\left(\frac{1}{\rho(q, q_{obs})} - \frac{1}{\rho_0}\right)\frac{\rho^n(q, q_{goal})}{\rho(q, q_{obs})^2} + a_2\frac{n}{2}\eta\left(\frac{1}{\rho(q, q_{obs})} - \frac{1}{\rho_0}\right)^2\rho^{n-1}(q, q_{goal}), & D(q) \leq \rho_0 \\ 0, & D(q) > \rho_0 \end{cases} \quad (4-17)$$

其中：

$$a_1 = \nabla\rho(q, q_{obs}) = \frac{q - q_{obs}}{\|q - q_{obs}\|} \quad (4-18)$$

$$a_2 = -\nabla\rho(q, q_{obs}) = -\frac{q - q_{obs}}{\|q - q_{obs}\|} \quad (4-19)$$

如图 4-8 所示，两张图的障碍物位置完全一样，图 4-8(a)使用的是经典的人工势场法，图 4-8(b)使用的是改进的人工势场法。分析图 4-8(a)可见，目标点邻域障碍物产生的斥力场显著强于引力作用，导致路径严重偏离最优方向；图 4-8(b)中改进算法通过动态调制引斥力场，在接近目标时显著降低障碍物影响，使绕行轨迹更贴近理论最优路径。




图 4-8 改进前后效果图

4.3.3 深度学习与改进人工势场法结合的避障方法

人工势场法凭借外部传感器数据能实时规划局部路径，有效避开障碍物。但速度采样计算量大，易使真实轨迹偏离模拟结果。结合视觉信息可增强无人车局部避障效能。因此，本节提出一种深度学习与改进人工势场法结合的局部避障算法，该算法采用两级规划架构：首先通过改进 PRM 生成全局参考轨迹，为无人车提供全局路径；随后基于深度视觉传感器实时构建环境感知模型，当检测到动态障碍物导致预设路径点不可达时，触发局部重规划机制。在局部避障过程中，改进的 APF 算法通过引入轨迹连续性约束，将模拟轨迹域内首个有效轨迹点的连续邻域点定义为动态局部目标，结合代价地图优化生成平滑避障路径，最终实现从全局规划到局部动态调整的自适应导航。将视觉检测结果结合到改进人工势场法，设计的新型评价函数为：

$$dection(v, \omega) = \begin{cases} discarded, & x_{ob} < x_{t+1} < x_{obmax} \\ c, & otherwise \end{cases} \quad (4-20)$$

式中， $dection(v, \omega)$ 为障碍物评价函数，用于评估轨迹与障碍物的关系； x_{t+1} 表示无人车下一时刻位置， x_{ob} 、 x_{obmax} 分别代表障碍物的坐标位置，若模拟轨迹穿越障碍物区域，则此轨迹将被舍弃；否则，障碍物评价函数的结果被设定为常数 c ，此时不考虑障碍物对轨迹的具体影响。通过障碍物评价函数，可

以判断路径是否侵入障碍物区域，并据此放弃那些进入障碍物区域的路径。这种有效的规划方法能够防止无人车与障碍物发生碰撞，并使其能迅速调整路径以避开障碍物，提高反应速度和避障效率。在无人车的运动过程中，视觉传感器被用于实时检测障碍物信息。若未检测到障碍物，无人车将沿全局规划路径行驶，仅需调整转向角速度以维持航向。一旦检测到障碍物，无人车将根据实时获取的障碍物方位和距离信息，动态调整线速度和角速度的组合，以实现避障，并同步更新局部代价地图。最终，当无人车到达目标点时，导航任务结束。流程图如下所示。




图 4-9 改进算法路径优化的流程图

4.4 本章结论

在本章中，主要对避障算法进行研究。首先，对无人车避障算法进行规划，其中包括全局路径规划和局部路径规划。接着针对全局和局部路径规划算法在动态环境下性能不够理想的问题，进行算法改进。然后，进行了避障规划仿真试验，实验结果显示，经过优化的算法显著增强了无人车的响应速度，并提高了其运动过程中的安全性。最后提出了结合深度学习信息的人工势场法，使无人车能够依据障碍物检测算法的输出结果，自主完成避障任务。

第5章 无人车路径规划和避障实验及分析

5.1 避障算法总体流程与系统运行环境

前文已完成对目标检测与路径规划算法体系的优化研究。第三章构建了基于改进 YOLOv7 算法的环境感知模型，第四章则分别提出了改进 PRM 全局路径规划算法和改进人工势场局部避障策略。本章将在上文研究基础上，系统开展无人车平台算法集成与实验验证工作，重点探究多算法协同作用下路径规划系统的实时性、鲁棒性及避障效能，通过实车测试环境构建完整的导航决策闭环。

5.1.1 避障算法总体流程

结合目标检测与改进后的避障算法，能互补优势，有效应对未知动态障碍和复杂场景，避障流程包括地图构建、全局路径规划、视觉障碍物检测、局部路径调整。

(1)构建全局地图。运动环境地图是无人车实现避障与路径规划的基础。为确保路径规划器能够设计出最优的行驶轨迹，必须采用定位建图算法对仿真或实际环境进行精确的地图构建。具体实践中，首先通过控制无人车在试验场地内移动多圈，这一过程中，利用 gmapping 算法执行全局定位与环境地图的构建任务为后续的路径规划与避障策略提供了至关重要的环境信息基础。

(2)全局导航策略。采用改进后的 PRM 算法进行全局路径规划，整合全局定位信息与拓扑地图数据，生成全局最优参考路径。该方法通过引入拓扑约束条件，将全局规划与动态避障模块进行耦合，显著提升系统对局部极值问题的鲁棒性。

(3)实时障碍物检测。无人车运行过程中，车载视觉感知系统通过多目摄像头阵列实时采集环境信息，经目标检测算法解析障碍物空间坐标及相对距离参数，最终形成结构化环境数据。该数据通过车载计算平台传输至动态避障决策模块，为路径规划算法提供实时环境感知输入。这种基于视觉传感器的环境感知方案，实现了障碍物检测与避障决策的闭环耦合，有效提升了无人车实时避障能力。

(4)动态路径优化。当检测到动态障碍物出现在规划路径时，系统立即触发改进的人工势场算法生成避障路径。在路径规划阶段，决策系统融合障碍物特征信息与高精度地图数据，构建轨迹评估矩阵对候选路径进行量化分析，通过多维度评估指标筛选出综合得分最高的避障方案。该最优路径决策结果通过运动控制接口转换为速度控制指令，经串口通信协议传输至底盘执行机构，驱动无人平台完成规避动作。整个流程实现了从环境感知到运动执行的闭环控制，有效提升了动态场景下的避障可靠性。这种集成了障碍物检测的实时局部路径规划技术，显著增强了无人车的响应速度，使其运动表现更加高效且稳定可靠，避障流程图如图 5-1 所示。




图 5-1 避障流程图

系统启动后依次完成参数初始化与环境建模，基于保存的地图执行自主导航任务。全局路径规划模块采用改进 PRM 算法生成最优全局路径，运动过程中通过视觉障碍物检测持续监测环境。当检测到障碍物时，动态优化模块实时重构人工势场模型生成避障轨迹，并同步更新局部环境数据库。完成避障后自动切换至全局路径跟踪模式，直至抵达目标坐标点。

5.1.2 系统运行环境

系统开发环境由上位机端的 VScode 集成开发环境、MobaXterm 终端工具及 ROS 机器人操作系统共同构建。本研究设计的无人车控制系统采用分布式架构，包含上位机决策系统与下位机执行系统两大部分。上位机系统通过串口协议与下位机控制器建立双向通信链路，实现数据交互与控制指令传输。上位机实时接收传感器采集的原始数据，并通过 ROS 消息机制发布标准化话题；决策算法解析控制指令后，结合车辆运动学模型生成轮速控制指令回传至执行机构，形成完整的控制闭环。系统架构包含 IMU、编码器里程计、激光雷达及 SLAM 模块，各节点通过 tf 树实现坐标系转换，最终完成定位、建图及路径规划任务。




图 5-2 上位机软件系统架构

ROS 内置的三维可视化工具 Rviz 极大地便利了 ROS 的开发与调试过程。通过 Rviz，开发者可以直观地显示传感器的数据、无人车的几何模型、规划的路径以及设定的目标点。如图 5-3 所示为 Rviz 整体界面。




图 5-3 Rviz 整体界面

5.2 目标检测实验及分析

针对室内动态障碍物检测场景，本研究构建了含人物目标的专项数据集。该数据集通过多源采集方式整合：基础数据取自 COCO 标准库和 VOC2007 测试集，并补充手动拍摄的室内场景图像，最终获得 500 张有效样本：其中训练集 350 张、测试集 150 张。为验证改进型 YOLOv7 算法的性能提升，本研究采用完全一致的实验配置包括参数设置及 100 轮次训练周期，分别在原始 YOLOv7 架构与改进模型上进行对比验证，结果如下：




图 5-4 改进 YOLOv7 模型前后的 $\text{map}@0.5$ 曲线

由图 5-4 所示，未改进的 YOLOv7 算法在识别人物作为移动障碍物时， $\text{mAP}@0.5$ 值在第 25 轮时开始收敛，最终平稳在 0.75，而改进后的 YOLOv7 算法在第 50 轮时开始收敛，虽然收敛速度较未改进时稍有落后，但改进后的 $\text{mAP}@0.5$ 值最终平稳在 0.80，比改进前增长了 6.7%；如图 5-5 所示，改进算法在人物目标检测任务中展现出显著优势，特别是在动态障碍物感知场景下，其检测精度与推理效率均获得有效提升。因此改进后的 YOLOv7 可以适用于此次实验环境。




图 5-5 算法前进前后结果对比

5.3 真实环境下无人车实验

5.3.1 调试设备及实验环境测试

实验采用一台移动无人车与电脑组合，利用 ROS 中的 Gmapping 算法结合 IMU、激光雷达及轮式里程计数据构建环境地图。同时为了能够成功连接无人车，需要在电脑下载 VScode 以及 MobaXterm 并连接同一个局域网。实验在设有障碍物实验室环境中进行，验证本文设计的基于深度学习的障碍物识别及无人车避障算法从起点至终点最佳路径时的实际效果。

5.3.2 地图构建测试

在 ROS 机器人框架中，本研究采用 gmapping 算法实现环境栅格地图的构建，同步获取载体位姿数据，并持续更新存储探索区域的地图数据。该过程通过传感器融合框架整合多源感知信息，在 Rviz 可视化界面中进行实时状态监测。地图构建阶段采用人工干预模式，操作人员通过键盘指令精准控制无人平台运

动轨迹，确保其在关键区域保持充分的数据采集时间，以获取完整的环境特征信息用于地图生成。该操作通过运动约束策略，有效避免了急转弯等不当运动引起的数据采集误差，显著提高了地图构建精度。在试验准备阶段，对算法模块进行了系统的参数优化配置，重点调试了传感器权重与数据采样频率等关键参数，保障所有感知设备的原始数据完整录入。这些前置性工作为后续的地图构建与精准定位任务提供了可靠的数据基础，确保了环境建模的全局一致性与定位解的稳定性。

首先需要准备好所使用的无人车，无人车上包括激光雷达、摄像头等。确保硬件能够正常工作，并且正确连接到计算机上。再配置无人车的驱动程序，使得 ROS 能够通过驱动程序控制无人车的运动，并且获取无人车的运动状态和传感器数据；然后通过 ROS 获取无人车传感器的数据；让无人车在环境中运动，并且使用 gmapping 功能包进行建图。通过 ROS 的可视化工具 RViz 等工具观察建图的过程和结果，记录建图的数据；最后对建图的结果进行分析，包括地图的准确性、一致性、完整性等方面。如果结果不理想，可以调整 gmapping 的参数，重新进行实验。如图 5-6、5-7 所示分别是无人车雷达参数配置以及激光雷达、里程计等坐标配置文件。

```
<launch>
  <node pkg="lslidar_x10_driver" type="lslidar_x10_driver_node" name="lslidar_x10_driver_node" output="screen">
    <param name="lidar_name" value="M10"/>          #雷达选择:M10 M10_P M10_PLUS M10_GPS M10
    <param name="serial_port" value="/dev/laser"/>   #雷达连接的串口
    <param name="interface_selection" value="serial"/> #接口选择:net 为网口,serial 为串口。
    <param name="child_frame_id" value="laser_link"/> #激光坐标
    <param name="scan_topic" value="scan"/>          #设置激光数据topic名称
    <param name="angle_disable_min" value="0.0"/>    #角度裁剪开始值
    <param name="angle_disable_max" value="0.0"/>    #角度裁剪结束值
    <param name="min_range" value="0"/>              #雷达接收距离最小值
    <param name="max_range" value="100.0"/>          #雷达接收距离最大值
    <param name="use_gps_ts" value="false"/>         #雷达是否使用GPS授时
  </node>
  <!-- (node name="rviz" pkg="rviz" type="rviz" args="-d $(find lslidar_x10_driver)/rviz/lslidar.rviz" output=
</launch>
```

图 5-6 雷达参数配置

```
<?xml version="1.0"?>
<launch>
  <arg name="use_rviz" default="true" />
  <!-- <include file="$(find racecar)/launch/includes/car_tf.launch.xml" /> -->
  <!-- ODOMETRY -->
  <!-- rf2o_Laser_Odometry-->
  <include file="$(find racecar)/launch/includes/rf2o.launch.xml" />
  <!-- wheel odometry -->
  <include file="$(find encoder_driver)/launch/wheel_odom.launch"/>

  <!-- Robot_Localization -->
  <node pkg="robot_localization" type="ekf_localization_node" name="ekf_se" clear_params="true">
    <rosparam command="load" file="$(find racecar)/param/ekf_params.yaml" />
  </node>
```


图 5-7 激光雷达、里程计等坐标配置文件

为了检测建图效果，在实验室布置障碍物进行实验。实验环境如图 5-8(a)所示，在场景中布置一些障碍物，使其地图环境变得复杂，对建图效果有一定

考验。对应的栅格地图分别如图 5-8(b)所示，图中采用了特定的颜色来表示不同的区域特征。灰色区域代表可通行的路径，意味着无人车可以在这些区域内自由移动；黑色区域则明确标识出障碍物的位置，即无人车应避免进入的区域；而墨绿色区域则表示未知区域，其安全性尚未确定，因此也被视为不可通行的区域。这种方式有助于我们快速而直观地理解地图信息，从而做出更为准确的导航决策。



(a)室内环境



(b) Rviz 地图画面显示

图 5-8 无人车所处室内环境实验

从图中可以清晰地观察到，无人车在室内环境下，能有效地进行地图构建。室内的圆柱筒、桌椅等障碍物均在栅格地图中得到了准确的呈现。所构建的地图模型轮廓平滑，障碍物边界清晰，与真实环境的布局高度一致。这表明，此建图方案不仅满足了基本的设计要求，而且在精度和实用性方面均达到了预期目标。


5.3.3 全局路径规划实验及分析

为验证所提全局路径规划算法的有效性，本节采用 PRM 算法与改进 PRM 算法，在复杂静态场景和动态障碍环境下开展对比实验。图 5-9、图 5-10 分别


展示了两种算法在不同场景下的路径规划结果，其中黑色实线表示规划的全局参考路径，黑色圆点标记预设的目标位姿。



(a)室内环境



(b)PRM算法的全局路径



(c)改进PRM算法的全局路径


图 5-9 场景一的全局路径规划效果对比



(a)室内环境



(b)PRM算法的全局规划



(c)改进PRM算法的全局规划

图 5-10 场景二的全局路径规划效果对比

在 Rviz 的可视化操作中，灰色区域代表全局代价地图，黑色区域为障碍物。当接收到目标点导航指令后，全局路径规划器基于全局代价地图，分别采用 PRM 算法与改进 PRM 算法进行路径规划，生成最优的参考路径。所生成路径

表 5-1 不同场景下全局路径规划性能指标对比

由上述实验的规划效果和表 5-1 数据对比可知，在使用改进的 PRM 算法进行全局路径规划时，生成路径平滑度、规划路径长度都优于改进前的 PRM 算法，且改进 PRM 算法通过复用历史搜索经验有效缩减采样空间，显著提升规划效率。

为验证结合了深度学习与改进人工势场算法的局部避障算法在应对环境中未知动态障碍物时的有效性，计划在真实场景下进行局部路径规划算法的实地测试。首先打开 VScode 和 MobaXterm，利用 SSH（Secure Shell，安全外壳协议）远程链接无人车主机。如下图 5-11、图 5-12 所示：

图 5-11 VScode 成功连接无人车

图 5-12 MobaXterm 成功连接无人车

/usb_cam/image_test，验证了主从节点间通信已有效连接。

```
Last login: Wed Mar 19 14:01:47 2025 from 192.168.31.201
ucar@ucar-mini:~$ rostopic list
/image_view/output
/image_view/parameter_descriptions
/image_view/parameter_updates
/rosout
/rosout_agg
/usb_cam/camera_info
/usb_cam/image_raw
/usb_cam/image_test
```

图 5-13 话题列表

当本地上位机中查阅到无人车主机发布的摄像头话题后即可打开 RViz 订阅话题节点进行可视化操作。在 RViz 中可以看到画面能够实时正常发布并且能够实时识别障碍物，以供给无人车主机的局部避障节点进行订阅，并获取视觉检测数据，如图 5-14 所示。




图 5-14 Rviz 可视化操作

利用上文所提到的 gmapping 功能包对本章实验环境进行地图构建。如图 5-15 所示，利用键盘控制无人车运动完毕后并执行 save_map.sh 脚本进行地图保存。




图 5-15 地图保存



图 5-16 室内实验环境




图 5-17 实验环境全局地图

使用构建好的全局地图，在 RViz 中进行数据可视化并在地图中给定目标点，在构建好的全局地图中，采用改进后的 PRM 算法生成全局参考路径，该参考路径经层级化规划架构传递至局部避障模块后，通过改进的人工势场算法实现动态环境感知与实时避障路径优化。如图 5-18 所示，黑色圆点为给定的目标到达点，黑色线段为规划的全局路径，绿色圆点为静止的行人，行人随无人车开始移动而移动。




图 5-18 行人静止时全局路径规划

如图 5-19 所示，展示了无人平台在真实场景中的避障行为过程，实验结果

表明：在室内动态环境中，当检测到行人等移动障碍物时，系统能够精准感知障碍物存在，并实时进行局部路径重规划，生成安全可行的绕行轨迹。实验数据验证了无人车避障功能的可靠性。与传统避障算法相比，本研究提出的改进算法在障碍物特征提取精度上提升显著，能够动态生成更优路径且能快速衔接至预设的全局导航路径，充分适应动态复杂环境下的避障任务需求。




图 5-19 无人车实际避障过程

当深度相机探测到移动障碍物时，会立即在局部代价地图中更新障碍物的信息。随后，结合目标检测的结果，采用改进后的人工势场法进行局部避障，从而生成最优的避障轨迹。最终，无人车会根据这一轨迹执行安全的避障动作。如图 5-20 所示，图中以黑色线段标记的是改进后的人工势场法结合视觉信息所规划出的局部最优避障路径。通过对比图 5-18 和图 5-20，可以明显看出，在无人车尚未感知到动态障碍物的前期导航阶段，局部路径规划器所生成的实时路径与全局参考路径保持了高度的一致性。图中绿色小点为行人当前位置，蓝色线段即是行人的运动轨迹。当无人车行进至实验场地中心，且其视觉系统成功识别出移动障碍物后，改进的人工势场法通过整合目标信息，在实时更新的局部代价地图上迅速规划出一条更短的避障路径。无人车将沿着这条路径快速完成局部避障，随后顺利返回到全局路径上，继续执行导航任务。




图 5-20 行人运动时无人车局部路径

5.4 本章小结

本章内容概述如下：首先，详细介绍了本文所提出的基于深度学习的避障算法的整体流程，以及该算法所需的系统运行环境。随后，为了评估算法性能，将改进前后的 YOLOv7 算法在实际数据集中进行了测试与对比验证。通过对算法性能的深入分析，得出了有关其准确性与效率等方面的评估结果。最后，为了验证算法在实际应用中的有效性，在真实环境下进行了全局路径规划和局部避障的实验，并对实验结果进行了详尽的分析。由实验结果可知，本文基于深度学习的障碍物识别及无人车避障算法有效适应典型室内动态环境，在局部未知场景中对突发移动障碍物实现精准感知与实时规避，该算法不仅满足室内场景实时性要求，更增强了移动障碍物交互避障能力，为复杂环境自主导航提供了可靠解决方案。

第 6 章 总结与展望

6.1 论文的主要工作

本文以室内含有移动障碍物的环境为应用场景，深入研究了视觉深度学习目标检测、全局导航和局部避障三个关键技术领域。特别是在局部避障方面，创新地将目标检测技术与改进后的人工势场算法相结合，这一结合有效辅助了无人车完成复杂的避障任务。实验结果表明，该方法显著提高了无人车在局部避障中的效率和成功率。全文主要工作如下：

(1) 针对无人车在算力和资源限制下目标检测精度低和检测效率差的难题，本文在 YOLOv7 算法的基础上，预测部分采用 WiSe-IoUv3 损失函数来优化网络，加入了 DyHead 注意力模块和 GAM 注意力机制，同时保持了良好的精度。同时加入 Slim 范式来减少网络的计算负荷和复杂度，实现了提升目标检测算法的检测精度的同时，提高检测效率。

(2) 针对在复杂环境下，传统路径规划算法可能会遇到局部最优问题导致无人车路径规划不理想甚至是规划失败的问题。为此本文在经过改进的人工势场算法以及 PRM 算法分别负责无人车的局部路径规划和全局路径规划，并引入三次样值轨迹平滑化处理，通过多次仿真和实验，无人车可以较好实时完成路径规划以及避障任务，满足实际场景的导航需求。

(3) 在无人车中对本文设计的避障算法进行了测试和验证，并对结果进行了分析。实验证明了本文所设计的基于深度学习的障碍物检测以及无人避障算法在真实环境测试中有效实现了对室内移动障碍物的实时检测与主动规避，验证了其可行性和有效性，满足复杂场景下的局部路径规划需求。

6.2 研究展望

随着未来走向自动化，无人车技术变得越来越重要，它能以更好的可重复性和准确性完成人类的工作。普及后，将极大便利公众出行，促进绿色物流，同时驱动汽车产业革新，开启智能交通新时代，展现巨大发展潜力。本研究虽

然已经较好实现无人车的障碍物识别功能和路径规划，但是其中仍然存在很多的不足和局限性。对于本文的研究方向还可以在以下几个方面做进一步的展望：

（1）随着社会的进步，本文所使用的 YOLOv7 算法相较于其他算法架构滞后，缺乏 Transformer 支持，小目标检测弱，速度精度平衡不及 YOLOv8 等变体及主流 Transformer 模型。后续可以改进更先进的目标检测算法，使其在更复杂的环境下仍然能保持较好的检测精度。

（2）本文路径规划实验均在室内环境下进行验证，后续研究可拓展至室外场景开展验证。针对实际应用需求，需重点优化算法鲁棒性，引入多源干扰变量建模，同时考虑光照变化、地面材质等环境扰动因素对系统性能的影响。通过构建复合型测试场景，使算法在存在行人流动、动态障碍物等外界干扰条件下，仍能稳定输出安全避障方案，最终实现复杂环境下的可靠导航能力。

参考文献

- [1] 李磊, 叶涛, 谭民, 等. 移动机器人技术研究现状与未来[J]. 机器人, 2002,(05): 475-480.
- [2] 梁荣健, 张涛, 王学谦. 家用服务机器人综述[J]. 智慧健康, 2016,2(02): 1-9.
- [3] 陈骞. 欧、美、日、韩机器人产业新战略[J]. 上海信息化, 2015,(03): 81-83.
- [4] Bakheet S, Al-Hamadi A. A framework for instantaneous driver drowsiness detection based on improved HOG features and naive bayesian classification[J]. Brain Sciences, 2021, 11(2): 240.
- [5] Fabio Bellavia. SIFT matching by context exposed[J], IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2445-2457.
- [6] Felzenszwalb P F, Girshick R B, McAllester D, et al. Object detection with discriminatively trained part-based models[J]. IEEE transactions on pattern analysis and machine intelligence, 2009, 32(9): 1627-1645.
- [7] Siuly S, Khare S K, Kabir E, et al. An efficient parkinson's disease detection framework: peveraging time-frequency representation and alexnet convolutional neural network[J]. Computers in biology and medicine, 2024, 174: 108462.
- [8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2014: 580-587.
- [9] Koklu M, Unlarsen M F, Ozkan I A, et al. A CNN-SVM study based on selected deep features for grapevine leaves classification[J]. Measurement, 2022, 188: 110425.
- [10] Girshick R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. 2015: 1440-1448.
- [11] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779-788.
- [12] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 7263-7271.
- [13] Zhang X, Dong X, Wei Q, et al. Real-time object detection algorithm based on improved YOLOv3[J]. Journal of electronic imaging, 2019, 28(5): 1-8.

-
- [14] Redmon J, Farhadi A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv:1804.02767, 2018,2(4):7-11.
 - [15] Bochkovskiy A, Wang C Y, Liao H Y M. Yolov4: Optimal speed and accuracy of object detection[EB]. arXiv:2004.10934, 2020.
 - [16] Wen H, Li Y, Wang Y, et al. Usage of an improved YOLOv5 for steel surface defect detection[J]. Materials Testing, 2024, 66(5): 726-735.
 - [17] Hernandez-Jimenez D E, Rodriguez-Nava E A, Trujillo-Ocampo F J, et al. Coordination of multiple wheeled mobile robots with convoy and delta formations[C]//2021 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME). IEEE, 2021: 1-6.
 - [18] Rostami S M H, Sangaiah A K, Wang J, et al. Obstacle avoidance of mobile robots using modified artificial potential field algorithm[J]. EURASIP Journal on Wireless Communications and Networking, 2019, 2019(1): 1-19.
 - [19] Lee D H, Lee S S, Ahn C K, et al. Finite distribution estimation-based dynamic window approach to reliable obstacle avoidance of mobile robot[J]. IEEE Transactions on Industrial Electronics, 2020, 68(10): 9998-10006.
 - [20] 张广帅, 韦建军, 刘检权, 等. 移动机器人导航的路径规划策略[J]. 机电工程技术, 2021, 50(04): 14-24.
 - [21] Lin M, Xiaoming J, Fei Q. A robot obstacle avoidance method based on improved genetic algorithm[C]//2018 11th International Conference on Intelligent Computation Technology and Automation (ICICTA). IEEE, 2018: 327-331.
 - [22] Zhang J, Zhang S, Gao R. Discrete-time predictive trajectory tracking control for nonholonomic mobile robots with obstacle avoidance[J]. International Journal of Advanced Robotic Systems, 2019, 16(5): 1729881419877316.
 - [23] 易先军, 耿翰夫, 付龙, 等. 模糊改进人工势场法移动机器人路径规划[J]. 组合机床与自动化加工技术, 2021, (05): 65-68.
 - [24] 黄泽霞, 邵春莉. 深度学习下的视觉 SLAM 综述[J]. 机器人, 2023, 45(06): 756-768.
 - [25] 吴宇, 郝万君, 曹选, 等. 改进蚁群与势场融合算法的平滑路径规划[J]. 计算机仿真, 2023, 40(03): 141-146.
 - [26] 姬鹏, 郭明皓. 基于 Frenet 坐标下改进人工势场法的无人车局部路径规划[J]. 兵工学报, 2024, 45(07): 2097-2109.

-
- [27] Wang D, Chen S, Zhang Y, et al. Path planning of mobile robot in dynamic environment: Fuzzy artificial potential field and extensible neural network[J]. Artificial Life and Robotics, 2021, 26: 129-139.
 - [28] 韩明,刘教民,吴朔媚,等.粒子群优化的移动机器人路径规划算法[J].计算机应用,2017,37(08):2258-2263.
 - [29] 杨天宇, 薛阳, 张亚飞. 基于蚁群-粒子群算法的巡检机器人路径规划[J]. 现代计算机(专业版), 2017, (29): 48-51.
 - [30] 王钦钊, 程金勇, 李小龙. 复杂环境下机器人路径规划方法研究[J]. 计算机仿真, 2017, 34(10): 296-300.
 - [31] 陈正升, 王雪松, 程玉虎, 等. 基于 ROS 的自主移动机器人路径规划虚实结合实验平台[J]. 实验技术与管理, 2023, 40(01): 77-82+100.
 - [32] Meng Z, Wang C, Han Z, et al. Research on SLAM navigation of wheeled mobile robot based on ROS[C]//2020 5th International Conference on Automation, Control and Robotics Engineering (CACRE). IEEE, 2020: 110-116.
 - [33] 陈卓, 苏卫华, 安慰宁, 等. 移动机器人 SLAM 与路径规划在 ROS 框架下的实现[J]. 医疗卫生装备, 2017, 38(2): 109-113.
 - [34] 王林荣, 黄涛. 基于 ROS 的激光 SLAM 室内建图定位导航智能机器人设计[J]. 无线互联科技, 2020, 17(4): 64-66.
 - [35] 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]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2023: 7464-7475.
 - [36] Wang C Y, Bochkovskiy A, Liao H Y M. Scaled-yolov4: Scaling cross stage partial network[C]//Proceedings of the IEEE/cvf conference on computer vision and pattern recognition. 2021: 13029-13038.
 - [37] Zhang X, Zeng H, Guo S, et al. Efficient long-range attention network for image super-resolution[C]//European conference on computer vision. Cham: Springer Nature Switzerland, 2022: 649-667.
 - [38] Liu S, Qi L, Qin H, et al. Path aggregation network for instance segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 8759-8768.
 - [39] Ding X, Zhang X, Ma N, et al. Repvgg: Making vgg-style convnets great

- again[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 13733-13742.
- [40] 成浪, 敬超. 基于改进 YOLOv7 的 X 线图像旋转目标检测[J]. 图学学报, 2023, 44(02): 324-334.
- [41] Kavraki L E, Svestka P, Latombe J C, et al. Probabilistic roadmaps for path planning in high-dimensional configuration spaces[J]. IEEE transactions on Robotics and Automation, 1996, 12(4): 566-580.
- [42] 林韩熙, 向丹, 欧阳剑, 等. 移动机器人路径规划算法的研究综述[J]. Journal of Computer Engineering & Applications, 2021, 57(18): 430-443.
- [43] 程谦, 高嵩, 曹凯, 等. 基于 PRM 优化算法的移动机器人路径规划[J]. 计算机应用与软件, 2020, 37(12): 254-259.
- [44] 邹善席, 王品, 韩旭. 基于 PRM 改进的路径规划算法[J]. 组合机床与自动化加工技术, 2019 (1): 1-3.
- [45] 贺颖, 周盈伶, 布升强, 等. 基于改进 PRM 算法的无人车路径规划研究[J]. 林业机械与木工设备, 2021, 49(5): 34-39.
- [46] 李静茹. 基于改进蚁群算法的多无人机协同路径规划研究[D]. 徐州: 中国矿业大学, 2020.
- [47] Dimitropoulos K, Barmoutis P, Grammalidis N. Spatio-temporal flame modeling and dynamic texture analysis for automatic video-based fire detection[J]. IEEE transactions on circuits and systems for video technology, 2014, 25(2): 339-351.
- [48] Valikhujaev Y, Abdusalomov A, Cho Y I. Automatic fire and smoke detection method for surveillance systems based on dilated CNNs[J]. Atmosphere, 2020, 11(11): 1241.
- [49] Barmoutis P, Stathaki T, Dimitropoulos K, et al. Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures[J]. Remote Sensing, 2020, 12(19): 3177.
- [50] Le N, Nguyen K, Nguyen A, et al. Global-local attention for emotion recognition[J]. Neural Computing and Applications, 2022, 34(24): 21625-21639.
- [51] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7132-7141.
- [52] 田枫, 白欣宇, 刘芳, 等. 一种轻量化油田危险区域入侵检测算法[J]. 智能系统学报, 2022, 17(3): 634-642.

-
- [53] Misra D, Nalamada T, Arasanipalai A U, et al. Rotate to attend: Convolutional triplet attention module[C]//Proceedings of the IEEE/CVF winter conference on applications of computer vision. 2021: 3139-3148.
 - [54] Li H, Li J, Wei H, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
 - [55] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 39(6): 1137-1149.
 - [56] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF international conference on computer vision. 2021: 10012-10022.
 - [57] Gao X, Li J, Fan L, et al. Review of wheeled mobile robots' navigation problems and application prospects in agriculture[J]. IEEE Access, 2018, 6: 49248-49268.
 - [58] Weidinger F, Boysen N, Briskorn D. Storage assignment with rack-moving mobile robots in KIVA warehouses[J]. Transportation science, 2018, 52(6): 1479-1495.
 - [59] Namba T, Yamada Y. Risks of deep reinforcement learning applied to fall prevention assist by autonomous mobile robots in the hospital[J]. Big Data and Cognitive Computing, 2018, 2(2): 13.
 - [60] Yan P. Research on the selection of path planning algorithm: A case study in Leeds[C]//Journal of Physics: Conference Series. IOP Publishing, 2022, 2179(1): 012039
 - [61] 姜媛媛, 张阳阳. 改进 8 邻域节点搜索策略 A* 算法的路径规划[J]. 电子测量与仪器学报, 2022, 36(5): 234-241.
 - [62] 周相坡, 周依尔, 徐立军, 等. 一种基于概率路线图的月球巡航车路径规划算法[J]. 空间控制技术与应用, 2021, 46(6): 43-49.
 - [63] 林依凡, 陈彦杰, 何炳蔚, 等. 无碰撞检测 RRT* 的移动机器人运动规划方法[J]. 仪器仪表学报, 2020, 41(10): 257-267.
 - [64] 程志, 张志安, 李金芝, 等. 改进人工势场法的移动机器人路径规划[J]. 计算机工程与应用, 2019, 55(23): 29-34.
 - [65] 王刚, 张方, 严大亮, 等. 基于改进蚁群算法的机器人三维路径规划[J]. 国外电子测量技术, 2020, 39(11): 1-6.
 - [66] 杨立炜, 付丽霞, 王倩, 等. 多层优化蚁群算法的移动机器人路径规划研究[J].

电子测量与仪器学报, 2021, 35(9): 10-18.

攻读学位期间发表的学术论文目录

(1) 发表论文

- [1] 杨思远, 王冠凌, 江自豪, 等. 基于改进 YOLOV7 的多场景火灾识别算法[J]. 红外技术. (已录用)
- [2] 江自豪, 杨思远, 王世康, 等. 改进 YOLOV7 的自动驾驶目标检测算法[J]. 传感技术学报. (已录用)
- [3] 桑建斌, 张梦雯, 杨思远, 等. 改进 YOLOV8n 的复杂场景行人检测算法[J]. 传感技术学报. (已录用)

(2) 获奖情况

- [1] 2022 年第十七届全国大学生智能车竞赛线下选拔赛航天智慧物流组比赛 安徽省三等奖。
- [2] 2023 年第十七届“西门子杯”中国智能制造挑战赛离散行业运动控制 全国初赛二等奖。
- [3] 2023 年第十八届全国大学生智能车竞赛线下选拔赛航天智慧物流组比赛 安徽省二等奖。
- [4] 2023 年第十八届全国大学生智能汽车竞赛南部赛区室外 ROS 无人车竞速赛 安徽省一等奖。
- [5] 2023 年第十八届全国大学生智能汽车竞赛全国总决赛室外 ROS 无人车竞速赛 全国一等奖。
- [6] 2024 年第十八届“西门子杯”中国智能制造挑战赛离散行业运动控制 全国初赛二等奖。
- [7] 2024 年第十九届全国大学生智能汽车竞赛地平线智慧医疗挑战赛 安徽赛区二等奖。

致谢

本研究及学位论文是在我的导师王冠凌老师和毛德平老师的亲切关怀和悉心指导下完成的。他们严肃的科学态度，严谨的治学精神，精益求精的工作作风，深深地感染和激励着我。王老师和毛老师不仅在学业上给我以精心指导，同时还在思想、生活上给我以无微不至的关怀，在此谨向王老师和毛老师致以诚挚的谢意和崇高的敬意。

我还要感谢在一起愉快的度过三年时光的实验室同学们，正是由于你们的帮助和支持，我才能克服一个一个的困难和疑惑，直至论文的顺利完成。在论文即将完成之际，我的心情无法平静，从开始进入课题到论文的顺利完成，有多少可敬的师长、同学、朋友给了我无言的帮助，在这里请接受我诚挚的谢意！

最后我还要感谢培养我长大含辛茹苦的父母，谢谢你们！再次对关心、帮助我的老师和同学表示衷心地感谢！

尚德敏学 唯实惟新

