

分类号：TP18

密 级：公开

学校代码：10363

学 号：2220320109



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 新型 HLO 优化算法及在 AGV
路径规划中的应用

论 文 作 者 王勤

校 内 导 师 魏利胜（教授）

校 外 导 师 张平改

专业学位类别 电子信息

研究方向（领域） 控制工程与自动化技术

论文提交日期：2025 年 5 月 10 日

分类号: TP18

密 级: 公开

单位代码: 10363

学 号: 2220320109

题 目 新型 HLO 优化算法及在 AGV 路径规划中的应用

题 目 Novel HLO Optimization Algorithm and its
Application to AGV Path Planning

学 生 姓 名: 王勤

校 内 导 师: 魏利胜教授

校 外 导 师: 张平改

专业学位类别 : 电子信息

研究方向(领域): 控制工程与自动化技术

论文答辩日期: 2025 年 5 月 10 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：王勤

日期：2025 年 5 月 10 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：王勤

指导教师签名：魏利胜

日期：2025 年 5 月 10 日

新型 HLO 优化算法及在 AGV 路径规划中的应用

摘 要

随着社会生产需求的不断提高以及科技水平的快速发展,自动导引车(Automated Guided Vehicles, AGV)在各个领域发挥着重要作用。AGV 路径规划是其核心问题,当前主要采用遗传算法(Genetic Algorithm, GA)、蚁群算法(Ant Colony Algorithm, ACO)、粒子群算法(Particle Swarm Algorithm, PSO)、人类学习优化算法(Human Learning Optimization Algorithms, HLO)等对 AGV 路径进行规划设计。考虑到传统优化算法,存在收敛速度慢、寻优精度低、规划轨迹不光滑等不足,从而影响 AGV 实际应用和推广。因此本文重点研究改进型 HLO 算法并将其应用于 AGV 路径规划领域,主要工作内容如下:

首先,针对单 AGV 全局路径规划问题,探讨了增强勤奋人类学习优化算法(Enhanced Diligent Human Learning Optimization Algorithms, EIHLO)。通过调整 HLO 算法的概率参数设计,自适应调整惯性权重系数,以增强局部寻优能力;同时引入 PSO 以改进个体学习算子和社会学习算子的更新操作,从而加快收敛速度;在此基础上,推导出 EIHLO 收敛性条件,利用测试函数测试,验证了所提 EIHLO 算法的有效性。

其次,针对单 AGV 局部路径规划问题,研究了 EIHLO 算法与动态窗口法(Dynamic Window Algorithm, DWA)混合的算法。考虑到传统 DWA 存在全局性差、避障性能较低等问题,利用 EIHLO 进行全局路径规划,提取全局路径规划的关键节点;在此基础上,引入改进 DWA 进行局部路径优化,并通过在 T 型陷阱环境和复杂的 40×40 环境下进行仿真对比,验证所提方法的可行性。

最后,针对多 AGV 路径规划问题,探讨了相互速度障碍法

(Reciprocal Velocity Obstacle, RVO)与改进 DWA 融合 HLO 算法。由于多 AGV 的路径时可能出现相遇冲突、节点冲突以及赶超冲突等工况,先利用 EIHLO 规划出全局路径,同时将 RVO 与改进 DWA 进行融合进行局部规划,以解决多 AGV 的避障问题。通过不同环境场景下仿真,结果表明,各 AGV 均能安全、有效避障,到达预定的目的地。

综上,本文探讨了改进型 HLO 算法及其在 AGV 路径规划的应用,以提高运行效率,降低运行成本,具有重要理论研究和实际应用价值。

关键词: 路径规划; AGV; 人类学习优化算法; 动态窗口法; 解决策略

Novel HLO Optimization Algorithm and its Application to AGV Path Planning

ABSTRACT

With the continuous improvement of social production needs and the rapid development of science and technology, Automated Guided Vehicles (AGV) play an important role in various fields. AGV path planning is its core problem, and at present, genetic algorithm (GA), ant colony algorithm (ACO), particle swarm algorithm (PSO), human learning optimization algorithms (HLO), and so on are mainly used to plan and design AGV paths. Learning Optimization Algorithms (HLO), etc. for planning and designing AGV paths. algorithm, Considering the traditional optimization algorithms, there are shortcomings such as slow convergence speed, low optimization accuracy, and non-smooth planning trajectory, thus affecting the practical application and promotion of AGV. Therefore, this paper focuses on researching the improved HLO algorithm and applying it to the field of AGV path planning, and the main work is as follows:

Firstly, the Enhanced Diligent Human Learning Optimization Algorithms (EIHLO) are explored for the single AGV global path planning problem. By adjusting the probabilistic parameter design of the HLO algorithm, the inertia weight coefficients are adaptively adjusted to enhance the local optimization searching ability; meanwhile, PSO is introduced to improve the updating operation of the individual learning operator and the social learning operator, so as to accelerate the convergence speed; on this basis, the convergence condition of the EIHLO is deduced, and the validity of the proposed EIHLO algorithm is

verified by utilizing the test function test.

Secondly, for the single AGV local path planning problem, the EIHLO algorithm Dynamic Window Algorithm (DWA) hybrid is studied. Considering the issues of poor global performance and low obstacle avoidance performance of traditional DWA, EIHLO is utilized for global path planning to extract the key nodes of global path planning; based on this, the improved DWA is introduced for local path optimization, and the feasibility of the proposed method is verified through comparative experiments in the type-trap environment and the complex environment.

Finally, the Reciprocal Velocity Obstacle (RVO) method with improved DWA fused with the HLO algorithm is explored most for the multi-AGV path planning problem. As the multi-AGVs may have encountered conflicts, node conflicts, and overtaking conflicts, the EIHLO is utilized to plan the global path first, while the RVO and the improved DWA are fused for local planning to solve the multi-AGV obstacle avoidance problem. The experiments simulated in different environmental scenarios show that each AGV can safely and effectively avoid obstacles and reach the intended destination.

In summary, the improved HLO algorithm and its application in AGV path planning are explored in this paper to improve operational efficiency and reduce operational costs, which has important theoretical research and practical application value.

Wang Qin (Electronic Information)

Supervised by Wei Lisheng

Key words: Path planning; AGV; Human learning optimization algorithm; Dynamic window method; Solution strategy

目 录

摘 要.....	I
ABSTRACT.....	III
目 录.....	V
第 1 章 绪论.....	1
1.1 研究背景与意义.....	1
1.2 国内外研究现状.....	2
1.2.1 AGV 研究现状	2
1.2.2 路径规划算法研究现状.....	3
1.3 论文研究内容和章节安排.....	5
第 2 章 基于 EIHLO 的单 AGV 全局路径规划.....	7
2.1 环境建模方法.....	7
2.2 EIHLO 的基本原理.....	9
2.2.1 基本模型.....	9
2.2.2 改进概率参数.....	12
2.2.3 IKD 与 SKD 更新操作	12
2.2.4 改进惯性权重系数.....	13
2.3 收敛性分析.....	13
2.4 函数极值优化仿真.....	16
2.4.1 针对低维基准函数.....	17
2.4.2 针对高维基准函数.....	18
2.4.3 测试函数图像及算法的收敛曲线.....	20
2.5 EIHLO 的路径规划仿真.....	25
2.5.1 路径规划实现流程.....	25
2.5.2 仿真及结果分析.....	27
2.6 本章小结.....	32
第 3 章 基于 EIHLO 和 DWA 的单 AGV 局部路径规划.....	33
3.1 DWA 的改进研究	33
3.1.1 AGV 运动学模型	33
3.1.2 DWA 速度采样	34
3.1.3 评价函数.....	35
3.1.4 动态改变权重系数策略.....	36
3.2 EIHLO 和 DWA 的混合算法	36
3.2.1 改进 DWA 局部路径规划仿真	36

3.2.2 混合算法流程.....	38
3.2.3 混合算法仿真及分析.....	39
3.3 本章小结.....	45
第 4 章 基于 EIHLO 的多 AGV 路径规划.....	46
4.1 冲突类型及解决策略.....	46
4.1.1 冲突类型.....	46
4.1.2 解决策略.....	47
4.2 改进 DWA 与 RVO 混合算法	48
4.2.1 互动速度障碍法.....	49
4.2.2 混合算法优化过程.....	52
4.3 混合算法的避碰仿真.....	54
4.3.1 相遇冲突仿真及分析.....	55
4.3.2 追赶冲突仿真及分析.....	57
4.3.3 节点冲突仿真及分析.....	60
4.3.4 其他情况仿真及分析.....	63
4.4 本章小结.....	64
第 5 章 总结和展望.....	65
5.1 总结.....	65
5.2 展望.....	66
参考文献.....	67
攻读学位期间发表的学术论文.....	70
攻读学位期间获得的奖励.....	70
致 谢.....	71

插图清单

图 1-1 研究内容框架图	5
图 2-1 可视图环境模型	7
图 2-2 栅格地图环境模型	8
图 2-3 拓扑地图环境模型	8
图 2-4 Voronoi 图环境模型	9
图 2-5 单峰测试函数图像及算法收敛图	22
图 2-6 多峰测试函数图像及算法收敛图	24
图 2-7 固定维数测试函数图像及算法收敛图	25
图 2-8 EIHLO 算法路径规划流程图	26
图 2-9 三种算法规划路径图	28
图 2-10 三种算法的收敛曲线图	29
图 2-11 三种算法的路径规划图	31
图 2-12 三种算法的收敛曲线图	31
图 3-1 运动学模型	33
图 3-2 动态窗口示意图	35
图 3-3 改进后的 DWA 与传统算法对比图	38
图 3-4 混合算法流程图	39
图 3-5 本文算法在 20×20 环境下的运行过程	41
图 3-6 不同算法路径对比图	42
图 3-7 混合算法路径及性能对比图	43
图 3-8 本文算法在不同环境下运行图	45
图 4-1 三种冲突类型图	46
图 4-2 DWA 解决冲突情况图	49
图 4-3 速度障碍法原理图	50
图 4-4 算法中存在的抖动现象	51
图 4-5 使用 RVO 算法消除抖动	51
图 4-6 互动速度障碍法原理图	52
图 4-7 RVO-DWA 算法原理图	53
图 4-8 多 AGV 路径规划算法流程图	54
图 4-9 解决相遇冲突过程	55
图 4-10 相遇冲突各 AGV 仿真结果性能对比图	57
图 4-11 解决追赶冲突过程	58
图 4-12 追赶冲突各 AGV 仿真结果性能对比图	60

图 4-13 解决节点冲突过程	61
图 4-14 节点冲突各 AGV 仿真结果性能对比图	63
图 4-15 其他情况仿真图	64

插 表 清 单

表 2-1 基准测试函数	16
表 2-2 HLO、HLOPSO、EIHLO 在低维基准函数的结果对比	17
表 2-3 HLO、HLOPSO、EIHLO 在高维基准函数的结果对比	19
表 2-4 20×20 地图规模仿真结果对比	29
表 2-5 30×30 地图规模仿真结果对比	32
表 3-1 改进前后对比	38
表 3-2 算法参数取值	40
表 3-3 几种路径规划算法性能指标对比	44
表 4-1 相遇冲突各 AGV 路径规划仿真结果	56
表 4-2 追赶冲突各 AGV 路径规划仿真结果	59
表 4-3 节点冲突各 AGV 路径规划仿真结果	62

第1章 绪论

1.1 研究背景与意义

自动导引车(Automated Guided Vehicles, AGV)发展至今已有 60 多年的历史,包含了多个领域技术。AGV 的产生表明在智能化控制方面科学技术发展水平产生了新的突破,也是 AGV 历史发展的一个新起点^[1]。AGV 能够根据事先编写好的程序规划出行驶路线,它具有系统稳定、定位准确、安全可靠、调度集中、效率高、人工成本低廉、输送平稳、作业自动化、柔性和重构性好等特点。随着当代信息处理技术与智能决策系统的迭代升级,AGV 自身在种类数目越来越复杂的同时应用范围也在向更广泛的方向发展。AGV 应用领域已突破传统工业边界,拓展至国家安全体系构建与深空探测等战略型的科研项目。在提升关键基础设施运行效能的同时,有效支撑了全球可持续性发展战略的实施,为构建智慧化社会生态提供了重要的技术保障。

在贯彻制造强国战略的实施路径中,需要构建智能技术创新应用体系,重点突破智能技术产业化应用瓶颈。通过深化机器学习与实体经济的融合路径,系统性提升智能技术研发效能与应用深度,为构建现代化产业体系提供核心驱动力^[2]。政策层面倡导将智能装备产业同新一代信息技术、机器学习等前沿科技深度的融合,重点推进 AGV 等智能装备的产业集成创新,以此驱动生产流程数字化重构与制造体系智能化转型。AGV 技术在我国工业领域的规模化应用,既折射出劳动力结构优化的现实诉求,更体现产业基础高级化与产业链现代化内生需求,成为我国突破传统制造模式、实现发展动能转换的重要技术载体。

目前,AGV 被广泛应用在很多行业,例如自动泊车、医疗、仓储物流、制造业、水下探测、航天、军事、资源开采、工业生产特殊行业及危险场合。自动物流成为典型应用场景,而且呈现爆发式增长态势。数据显示,随着精益管理理念的深度普及、人力成本持续攀升以及生产系统自动化需求的指数增长,推动企业加速部署智能化程度更高的 AGV 系统。这种技术扩散趋势既源于现代工业体系对柔性生产的内在要求,更得益于 AGV 在运行效率、环境适应性等方面的技术优势,预示着其在工业场景的应用将持续拓展。值得关注的是,当前 AGV 优化算法的工程化应用仍存在局限性,现有实证研究表明,在复杂拓扑结构作业区

域内, 现有算法普遍存在路径冗余度过高、收敛性易受局部极值干扰、计算资源消耗过大等缺陷, 导致规划效率与安全难以满足复杂动态环境需求^[3]。因此, 如何优化目前已有的路径规划算法, 构建适应多种场景需求的自主避障, 已成为提升 AGV 系统鲁棒性与经济性的关键突破口, 对推动最优路径效能提升具有的应用价值。

1.2 国内外研究现状

1.2.1 AGV 研究现状

当今社会对 AGV 的理论知识已有深入研究, 拥有较成熟的 AGV 技术。福特公司开创了自动引导车工业应用的开端^[4], 第一台 AGV 在美国诞生为物流专门设计。随后英国研制出电磁信号导向 AGV^[5], 斯坦福大学将摄像头和传感器应用于 AGV 探测周围环境, 使其具备自主性^[6]。日本研制出世界上第一个全尺寸人形的“智能”机器人, 不久后二代机器人在一代的基础上进行了改进表现出了更加人性化的能力^[7]。此后随着美国的火星探索计划的推出, 研发了全球第一台火星车。随着科技的进步, 德国提出工业战略使 AGV 智能化程度显著提高^[8], 如德国所发布智能家居清洁机器人, 其采用激光技术对工作区域的空间范围、障碍物信息等重要因素进行扫描, 能够快速掌握所需清洁的环境区域, 并以全局规划的方式来完成家居环境的清洁工作, 减轻了人们清洁工作的负担, 谷歌研发的无人车在道路上行驶实现自主避障。

近年来, 随着中国制造业和物流业的快速发展, 对 AGV 的需求日益增长, 国内企业和研究机构加大了对 AGV 技术的研发投入。国内 AGV 产品已逐渐覆盖中低端市场, 并开始向高端市场拓展。研究者也在积极研究 AGV 的路径规划、避障技术、多车协同控制等关键技术, 并取得了一定的成果。作为我国首台国产智能装备“冶钢 1 号”, 提升了我国工业机器人技术自主化水平。北京第一台电磁导向的移动机器人用于起重搬运工作^[9], 为 AGV 在中国的应用奠定了基础。第一台依靠超声波导航的移动机器人在特定的环境中行走由哈尔滨工业大学研制^[10]。国科大顺利地研发出了中国首台类人型机器人, 清华大学研制出了具有多功能、具备环境感知与路径规划能力的自主导航机器人^[11]。随着我国深空探测工程的稳步推进, 探月车出现在标志着我国智能装备领域已达到国际先进水平。2023 年, 我国产业链中实现亿元以上营收的企业数量超过 50 家, 这不仅证明我

国行业技术应用进入规模化发展阶段,更表明我国在该领域已具备参与全球科技竞争综合实力^[12]。党的十八大以来,党中央把发展人工智能提升到战略高度,中国经济已由高速增长阶段转向高质量发展阶段,正处于历史性转型的关键期,迫切需要新一代人工智能等智能技术创新培育新质生产力,作为战略性技术引擎的人工智能,将在促进产业高级化和经济体系现代化进程中发挥核心作用。

1.2.2 路径规划算法研究现状

路径规划是 AGV 系统的核心技术,是 AGV 系统中最重要的工作;同时,也是当前国际上的研究热点,其基本目的是多项评价指标约束下,AGV 能够在未知的环境中,从起始点移动到指定的终点,并满足安全要求且全局付出成本最小^[13-14]。近年来,国内外学者相继提出了多种路径规划方法。许多研究学者是在原有的算法上对其进行改进,如 Luo 等^[15]提出引入差别信息素以加速算法的收敛,该算法通过在后面两个步骤中使用信息素惩罚函数,有效地解决了死锁问题。Phung 等^[16]提出了一种通过球矢量优化的 PSO,通过建立目标函数,将轨迹规划问题转化为最优问题,利用粒子位置、无人机飞行速度和不同角度之间的关联,高效地寻找最优航迹。Fernandes 等^[17]提出的算法能够有效避免局部最优解。Jerald 等^[18]改进的 GA 使得机床设备利用率高、空闲时间少、减少惩罚成本。智能仿生算法的实时性差,适用于静态环境和全局路径规划。通过针对上述问题,佟云昊等^[19]探讨了在每一次迭代过程中,通过调整信息素释放系数、信息素更新准则、引入启发因子等方法,提高信息素更新准则。张浩等^[20]提出一种基于激活函数统计迭代的 ACO,采用 Sigmoid 激活函数分布策略,增加路线上信息素浓度,降低盲目性;增加蚂蚁选择全局最优节点的期望程度,减少算法的收敛时间。Yan 等^[21]探讨了传统动态窗口法倾向于绕过密集障碍物外部,导致移动距离增加的问题,引入当前点到目标点的距离作为新的约束条件。同样针对环境中障碍物较为密集出现问题,Tan 等^[22]提出引入障碍物搜索角概念,避障性能更优。Zhang 等^[23]提出对动态窗口法进行改进,周围环境信息进行分析时,利用模糊控制的方法确定评价函数的权重系数,提高算法的寻优效果。胡庆朋等^[24]探讨了由正太分布直接宏观改变转移概率的用于路径规划的 ACO。李开荣等^[25]提出了一种改进转角约束的 ACO,降低了的转弯频率。路径规划中会出现死锁问题,为解决这一难题,杨立炜^[26]探讨新的状态转移规则,解决路径紧贴障碍物的问题;改进距离启发式函数,增加蚂蚁局部探索时直行的几率。李涛等^[27]提出了


一种基于达尔文进化论的 ACO, 不仅解决了死锁问题而且提高搜索效率。Zhang 等^[28]通过结合邻接矩阵和奖励矩阵, 提出一种用于路由规划的低维邻接-奖励矩阵, 提高了传统 Q 学习算法效率, 加快了动态路线规划。

另一些学者是将两种算法融合改进算法效率, 如 Liu 等^[29]研究了信息素场梯度传导与几何拓扑优化的相结合。在蚂蚁搜索路径时, 其路径上的信息素将沿着势场作用力的方向进行扩散, 使蚁群的搜索范围缩小。Yu 等^[30]探讨了融合模拟退火算法, 引入 PSO 提高多样性, 通过建立解空间, 遍历性约束方程有效抑制局部收敛。Riahi 等^[31]研究发展的元启发式融合架构, 通过整合蚁群算法的概率决策模型与退火算法的热力学平衡准则, 使路径优化收敛效率优于传统的方法。Che 等^[32]提出基于 PSO 算法的改进 ACO 算法。该方法采用了一种新的信息素更新准则, 并采用粒子群算法进行启发, 在不与复杂障碍物冲突的情况下, 将所选择的节点与水下环境相结合, 寻找出最佳路径。王松涛等^[33]研究了两种不同的算法进行融合, 既能有效地解决问题的局部极值, 又能降低迭代次数。胡治锋等^[34]研究了一种 GA 与 ACO 融合算法, 结合两种优化方法的优点, 进一步提高了搜索全局最优解的效率。PSO 在具有初始收敛快、后期易陷入局部极值特点。为解决这种问题, 研究人员提出了各种改进方法。而徐洁等^[35]探讨了改善累积弯曲角度的方法, 通过引入弯曲抑制算子以平滑路径和 ACO 与 A* 算法相结合的优化模型, 减少路径弯曲次数, 使得路径轨迹整体平滑。杜云等^[36]研究了 GA 与 PSO 相结合算法, 并且调整策略惯性权重值的方法, 虽然可以求出最优解但算法效率并未提升。而王翼虎等^[37]研究 PSO 与细菌觅食算法相结合, 虽然使得粒子的寻优能力有所提高, 但该方法在后期易陷入局部极值。付兴武等^[38]提出了一种基于粒子群的天牛须寻优算法, 有效地避开障碍物, 但存在收敛速度较慢问题。程泽等^[39]研究 PSO 与免疫算法相结合的方法, 对具有高适应值的粒子进行复制和克隆变异, 但该方法粒子的多样性降低, 不便全局搜索。王利民等^[40]提出对 A* 算法进行改进, 去掉了多余的结点, 改进搜索方式和评价函数以此来提高算法速度, 通过调整 DWA 代价函数中的权值比例提升避障性能。刘旭等^[41]提出了一种融合蚁群 A* 算法, 将启发式方法的思想融入到 ACO, 优化搜索效率; 引入最值蚂蚁系统, 提出一种精英蚂蚁信息素更新规则, 改善了路径规划效率。Liu 等^[42]利用势能场提出 PE-A* 算法, 仿真证明 PE-A* 算法规划路线的可行性, 同时实现全局路线规划和局部避撞, 提高规划路线的安全性。

上述研究结果表明，目前学者们已提出各种路径规划优化算法且取得一些成果，但寻优能力、收敛精度和迭代速度仍有较大提升空间。因此，如何有效提高算法性能，解决复杂环境路径规划问题，提高规划效率和减少成本值得探讨。

1.3 论文研究内容和章节安排

本课题主要围绕 EIHLO 在 AGV 路径规划领域中的应用展开研究。为了解决现有算法在复杂场景的路径规划过程中存在的缺点，比如收敛效率低下、运动轨迹曲率频繁变化及冗余节点过多等缺陷，探讨改进人类学习算法用于提升最优路径的生成效率，以及在 AGV 局部路径搜寻时，传统 DWA 存在对环境适应性较差的问题，针对存在的问题对 DWA 进行改进。对多 AGV 在路径规划中可能存在的冲突，提出解决策略。设计基于 RVO 和改进 DWA 的混合算法进行多 AGV 路径规划。使用 MATLAB 仿真软件验证，对改进后的算法进行了可信性和有效性分析。本文的总体架构及各章的重点如图 1-1 所示：



第 1 章：阐述了论文的选题背景及意义，分析了当前 AGV 及路径规划算法

国内外研究现状;

第 2 章: 探讨了一种增强勤奋人类学习优化算法(Enhanced Diligent Human Learning Optimization Algorithms, EIHLO)。首先, 介绍了几种常见的环境建模方法, 通过比较不同的建模方法, 选用栅格图法作为环境建模。其次, 针对人类学习优化算法(Human Learning Optimization Algorithms, HLO)易陷入局部最优的缺点进行改进; 最后, 证明其收敛性并在 MATLAB 中应用于 CEC 测试函数及路径规划, 证明了 EIHLO 具有一定的优越性与可靠性。

第 3 章: 研究了 EIHLO 与 DWA(Dynamic Window Algorithm, DWA)混合的算法。首先, 针对 DWA 存在的缺陷, 对其评价函数做了改进, 在评价函数中加入角评价函数, 避免与障碍物的夹角过小、动态改变速度评价函数和角评价函数权重以调节速度及角度。其次, 对改进 DWA 进行路径规划仿真, 证明改进的可行性。最后, 将其与 EIHLO 结合, 将其应用于不同环境中的单 DWA 路径规划, 并于其他算法进行对比验证算法的可行性。

第 4 章: 探讨了相互速度障碍法(Reciprocal Velocity Obstacle, RVO)与改进 DWA 混合的算法。首先, 针对多 AGV 路径规划问题, 分析了 AGV 运动环境之间可能发生的冲突类型, 并依据冲突类型设计相应解决方案; 其次, 将 RVO 与 DWA 混合; 最后, 利用混合算法在多 AGV 复杂场景下实现高效无碰撞路径规划, 并通过仿真加以验证。

第 5 章: 总结本文的主要研究工作, 并指出下一步研究思路及未来发展趋势。

第2章 基于 EIHLO 的单 AGV 全局路径规划

2.1 环境建模方法

在路径规划前，首先要对环境建模，并将环境信息转化对应的环境模型中。下面对几种常见的环境建模方法进行详细介绍，并对它们的优势和不足进行分析。

1) 可视图法

可视图法基本思路为：在二维平面下，对三维的 AGV 进行理想质点化，将 AGV 视为平面坐标系中的单位长度实心圆形投影，对复杂场景中的非结构化障碍用多边形轮廓近似描述，再将起点、终点以及障碍物各个顶点相连接，生成无法穿透任何障碍物边界的可行链路集合^[43]。可视图法易于创建适用于局部路径规划、易识别目标和理解。尽管可视图法在某些方面具有优势，但它也存在一些局限性，可视图法主要适用于静态环境，难以处理动态障碍物或环境变化。可视图模型如图 2-1 所示。




图 2-1 可视图环境模型

2) 栅格地图法

栅格地图法基本思路为：利用二进制信息，把连续空间转化分解为等距二维单元矩阵。严格遵循空间对应准则，即每个离散单元的几何属性与真实环境的物理特征保持精确映射关系。此方法具有易于创建的特性、高效准确、结构清晰的优势，同时具有表达不规则障碍物的能力。如图所示栅格地图分为两种，白色表示允许通行区；黑色表示禁止通行区。栅格地图中的网格元素尺寸对轨迹规划的准确性与效率有着重要的影响^[44]。AGV 仅在网格中心点运动，网格中心点与网格的坐标相对应。栅格图模型直观地展示了栅格地图的基本结构，为进一步研究路径规划研究奠定了坚实的基础，栅格地图模型如图 2-2 所示。




图 2-2 栅格地图环境模型

3) 拓扑地图法

拓扑地图法基本思路为：用一组点和连接线来表达当前的环境信息^[45]，通常是以围的形式来表达一个环境的连通性，而一些关键点则是拐点等为代表。拓扑结构不用测量环境数据，更关心 AGV 定位相关的环境数据，拓扑地图法的优点是实时性高、建模简单、效率高、存储空间需求低、有成熟的推理和高效的图形搜索算法还可以与其他几何模型结合。但不适用于需要定位场合，当环境中障碍物较多，同样无法有效的规划出路线。拓扑图环境模型如图 2-3 所示。




图 2-3 拓扑地图环境模型

4) Voronoi 图法

Voronoi 图法基本思路为：对于给定的生成元集合，将任意空间位置划归到距离其最近的生成元所辖区域^[46]。这种基于邻近关系的几何划分方法所生成的平面网格结构即为经典 Voronoi 图，该模型的特征在于每个生成元对应的区域呈现为具有明确几何特征的多边形单元。Voronoi 图的环境建模方法具有高效性，能够快速生成环境的拓扑结构，为保证 AGV 的安全运行，增加了路径和障碍物的间距，生成路径具有清晰的拓扑结构，但也存在一些局限性，存在着拐点多、冗余多、动态环境适应性差、路径平滑性不足等问题，严重影响 AGV 的路径规

划效率。Voronoi 环境模型如图 2-4 所示。




图 2-4 Voronoi 图环境模型

对几种地图的优缺点进行分析比较,可以得出,栅格地图具有便于理解、能够清晰地描述地图环境、容易与其他优化算法相结合的优点。因此本文选取栅格法构建地图模型。

2.2 EIHLO 的基本原理

人类学习优化算法^[47]的灵感来源于人类行为,改进了演化机理和人类行为的智能优化算法。它模仿人的学习机理,以求出最优解,并具有较强的全局寻优能力。人类学习方式主要有三种:一是随机学习,人们在求解问题时,由于缺乏经验,往往采取随机学习的方法。二是个体学习,人类从自己先前的经验中了解到有利信息,进而规避相似错误,提高人类的学习效率。三是从社会群体学习,人类会从社会群体中获取最优经验,从而提升自己认知水平与学习效率。尤其是面对复杂问题时,学习社会群体中最优经验知识能够帮助个体打破固定思维^[48]。

在 EIHLO 利用随机学习算子、个体学习算子、社交学习算子等三种学习算子,分别模仿人的三种学习行为进行优化搜索。

2.2.1 基本模型

1) 初始化种群

首先进行种群初始化,然后分别进行迭代运算成新的候选解。二进位编码架构被应用于 EIHLO,一个二进制串可以表示一个个体,公式表示为:

$$x_i = [x_{i1} \ x_{i2} \ \dots \ x_{ij} \ \dots \ x_{iM}], 1 \leq i \leq N, 1 \leq j \leq M \quad (2-1)$$

其中, x_i 表示 i 个个体, N 表示群体大小, j 表示第 j 个元素, M 解决方案中的元素数目,其中每个候选解由若干独立的知识单元构成,编码序列各位置状态按均匀分布概率模型进行随机赋值(取值为 0 或 1),代表人们想要学习并且掌握的知识或技能。根据预设的种群规模参数,实现 EIHLO 初始群体的多样性保障。

EIHLO 的初始种群公式表示为:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \\ \vdots \\ x_N \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & \cdots \\ x_{21} & x_{22} & \cdots & \cdots \\ \vdots & \vdots & & \vdots \\ x_{i1} & x_{i2} & \cdots & \cdots \\ \vdots & \vdots & & \vdots \\ x_{N1} & x_{N2} & \cdots & \cdots \end{bmatrix} \quad (2-2)$$

2) 学习算子

① 随机学习算子

在人类学习一个新的技能时，由于缺乏经验和知识，人类会通过随机学习来掌握新的技能，EIHLO 算法通过随机学习算子来模拟这种行为，公式表示为：

$$x_{ij} = Rand(0,1) = \begin{cases} 0, & 0 \leq rand() \leq 0.5 \\ 1, & \text{else} \end{cases} \quad (2-3)$$

其中， x_{ij} 表 i 个个体的第 j 位， N 和 M 分别为个体的个数和解的维数。 $Rand()$ 是 0 和 1 之间的随机数。

② 个体学习算子

在掌握一定的知识经验之后即进行个体自我学习，虽然知识或经验可能并不完整，但是它却可以为个人的学习提供一个参照，构建经验回放机制实现错误经验识别与规避，从而提高学习的效率和准确性。EIHLO 通过建立个性化知识库 (Individual Knowledge Database, IKD) 来保存个体的最优体验，从而实现对个体的学习，公式表示为：

$$ikd_i = \begin{bmatrix} ikd_{i1} \\ ikd_{i2} \\ \vdots \\ ikd_{ip} \\ \vdots \\ ikd_{il} \end{bmatrix} = \begin{bmatrix} ik_{i11} & ik_{i12} & \cdots & ik_{i1j} & \cdots & ik_{i1M} \\ ik_{i21} & ik_{i22} & \cdots & ik_{i2i} & \cdots & ik_{i2M} \\ \vdots & \vdots & & \vdots & & \vdots \\ ik_{ip1} & k_{ip2} & \cdots & ik_{ipi} & \cdots & ik_{ipM} \\ \vdots & \vdots & & \vdots & & \vdots \\ ik_{il1} & ik_{il2} & \cdots & k_{ilj} & \cdots & ik_{ilM} \end{bmatrix} \quad (2-4)$$

其中， $1 \leq i \leq N, 1 \leq q \leq H, 1 \leq j \leq M$ ， ikd_i 表示第 i 个的个体知识库 IKD， L 是 IKD 中存储的解数目， ik_{ip} 表示第 i 个的第 p 个最优解。而 p 表示任意整数，用来确定在个人学习进程中，具体选择 IKD 中哪个个体。EIHLO 算法在个体学习过程中，根据相应的问题生成 IKD 中的数据的新解决方法，公式表示为：

$$x_{ij} = ikd_{ipj} \quad (2-5)$$

③ 社会学习算子

个体学习过程不仅缓慢、效率低下且只能解决简单的问题。遇到更加复杂问题时，人类会通过社会群体经验沟通学习，避免了因个人思维局限而产生的认知偏差，更加快速地掌握新技能，促进个体认知体系的系统化发展。在经验分享过程，实现了学习经验的精准映射，建立了多维认知网络间的关联，为学习持续演进提供了可验证的理论框架。为了最大限度地发挥社交学习策略对知识转移的有效性，构建一个保存在社交学习中获取经验的社会知识数据(Social Knowledge Database, SKD)，方便后续进一步的学习与创新，公式表示：

$$skd_i = \begin{bmatrix} skd_1 \\ skd_2 \\ \vdots \\ skd_q \\ \vdots \\ skd_H \end{bmatrix} = \begin{bmatrix} ik_{11} & ik_{12} & \dots & ik_{1j} & \dots & ik_{1M} \\ ik_{21} & ik_{22} & \dots & ik_{2j} & \dots & ik_{2M} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ ik_{q1} & ik_{q2} & \dots & ik_{qj} & \dots & ik_{qM} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ ik_{H1} & ik_{H2} & \dots & ik_{Hj} & \dots & ik_{HM} \end{bmatrix} \quad (2-6)$$

其中， $1 \leq i \leq N, 1 \leq q \leq H, 1 \leq j \leq M$ ， H 是 SKD 的数量， skd_q 是 SKD 中的第 q 个社会经验。将新产生的解从 SKD 中随机选取其中一个最佳方案，并将对应的二进制值进行拷贝。这样，EIHLO 就可以利用 SKD 中的知识来产生一个新的备选方案，并对其进行社会学习。公式表示为：

$$x_{ij} = sk_{qj} \quad (2-7)$$

EIHLO 采用随机学习算子、个体学习、社会习算子等方法产生新的求解方案，并利用 IKD、SKD 等已有的知识来寻找最优解，类似于人的学习过程，实现对全局探测与局部探测能力的有效均衡，进而提升优化效果。这三个形式的学习可以被进一步合并，公式表示为：

$$x_{ij} = \begin{cases} Rand(0,1), & 0 \leq rand() < pr \\ ik_{ipj}, & pr \leq rand() < pi \\ sk_{qj}, & else \end{cases} \quad (2-8)$$

其中， pr 代表随机学习的可能性， $pi - pr$ 、 $1 - pi$ 的值分别代表个体学习、社会学习的可能性。

2.2.2 改进概率参数

根据 EIHLO 的结构, 参数 p_r 和 p_i 非常重要, 它们直接决定学习与发展的协同关系, 在算法全局与局部搜索优的动态均衡, 从而影响了整个算法的性能, 使得 EIHLO 更有效地提高三个学习算子的学习能力。为使整个种群学习更加勤奋、提高学习效率对 p_r 和 p_i 表示为:

$$\begin{aligned} p_r &= pr_{\max} - (pr_{\max} * pr_{\min}) / magen \\ p_i &= pi_{\min} + (pi_{\max} * pi_{\min}) / magen \end{aligned} \quad (2-9)$$

其中, $pr_{\min} / pi_{\min}$ 和 $pr_{\max} / pi_{\max}$ 分别为 p_r / p_i 的最小值和最大值, $magen$ 为搜索的迭代次数。改进后的 p_r 和 p_i 随着 $magen$ 的增加而减小, 随着搜索的进展, 找到了越来越多的最优解, 种群的不确定性逐渐降低, 不仅有利于提高局部搜索能力, 并进一步引导整个群体更好地学习全局最优信息, 避免陷入局部及提高整体算法的精度。 p_r / p_i 可以更好的在勘探和开发之间实现更好的权衡。

2.2.3 IKD 与 SKD 更新操作

PSO 与其他的启算法相比, 有易于实施、操作简单、调整的参数数量较少等优点, 且与 HLO 算法结构更相似, 两者均以群智能理念为基础, 通过群体中个体之间的信息共享和协同搜索优化问题。但 PSO 难以兼顾全局搜索能力与局部最优搜索能力。通过连续执行两个经典的元启发式算法, 解决全局搜索和局部最优的精细搜索之间的平衡问题。迭代初期, 改进算法以第一个经典算法的输出是第二个的输入的方式引入混合元启发式算法, 在第一次迭代循环的时候将 EIHLO 的最优值输出引入 PSO 的输入, 能有效地加快收敛速度。从第二代开始将更新的 IKD 和 SKD 引入粒子群的速度更新公式表示为:

$$v_i = w * v_i + c^1 rand() (IK - x_i) + c^2 rand() (SK - x_i) \quad (2-10)$$

其中, v_i 是第 i 个粒子的速率, w 表示惯性系数, $rand()$ 是均匀分布在 (0,1) 之间的数, IK 是第 i 个粒子目前为止发现的个体学习中最好的学习经验, SK 是目前为止发现的整个社会群体中最好的学习经验。 x_i 表示最新的位置, c^1 和 c^2 是不同的学习因子。

二者是迂回相互牵制, 在知识获取与应用的进程中, 可以将学习经验快速传播整个群体, 避免陷于局部最优, 在共享经验时, 能够从不同角度去审视问题, 对解空间进行更深入的研究, 并对其进行准确的局部搜索, 以求得到最优解。

2.2.4 改进惯性权重系数

PSO 作为启发式算法,通过对鸟群觅食行为的观察和研究发现,鸟群体内个体间存在合作与竞争等复杂性行为。保持了以群体为基础的全局寻优策略,该方法将粒子群的初始化随机解进行迭代搜索。对粒子群速度更新中惯性权重系数进行改进表示为:

$$w = w_{\min} + (w_{\max} - w_{\min}) * \left[1 / \left(1 + \left(\frac{4\text{magen}}{\text{max}_{iter}} \right)^4 \right) \right] \quad (2-11)$$

其中, $w_{\max}$ 、 $w_{\min}$ 分别是 w 最大最小权重系数。 max_{iter} 是最大迭代次数。在搜索前期粒子群向外扩散搜索,寻找最佳全局路径。随着算法的进行,惯性系数作用于搜索步长与移动速率维度,随着迭代次数逐渐增加, w 不断减小,速度不断减小,提高局部搜索性能,搜索时间减小。群体多样性保持策略通过约束条件作用于粒子运动轨迹,粒子就会不断地寻找个体的极大值和整体极大值,直到满足指定的迭代代数或者最小错误为止。

2.3 收敛性分析

EIHLO 的收敛性是指种群在演化计算框架下,群体智能状态通过迭代演化机制促使 IKD 和 SKD 达到动态均衡。收敛性判别是判断当前解的最佳的一种有效判据,由于马尔科夫链模型^[49]在描述状态转移概率矩阵方面的数学完备性,从理论上证明该方法的收敛性,建立马尔科夫链的数学模型,并证明 EIHLO 种个体知识库序列为有限的齐次马尔科夫链;通过分析马尔科夫链的相关性质,得出 EIHLO 算法群体状态序列必将进入最优状态。

定义 1^[50]: 设 $\{Y^{(k)}, k \geq 0\}$ 为一列数值离散的随机变量,离散变量围成集合为 $S = \{j\}$, S 为状态空间, k 为任意时刻,对 $k \geq 1, i^{(l)} \in S (l \leq k+1)$ 有:

$$p(Y^{(k+1)} = i^{(k+1)} / Y^{(k)} = i^{(k)}, \dots, Y^{(0)} = i^{(0)}) = p(Y^{(k+1)} = i^{(k+1)} / Y^{(k)} = i^{(k)}) \quad (2-12)$$

则称其为马尔科夫链。

设 $x(t)$ 为 EIHLO 的第 t 代种群, IKD 为 EIHLO 算法的第 t 代个体知识库, N 是实时群体规模和个体知识库中的总合。

定理 1: EIHLO 算法个体知识库序列 $\{IKD(t), t \geq 0\}$ 是有限随机马尔可夫链。

证明: 设为 $Y(t)$ EIHLO 的第 t 代种群, IKD 为 EIHLO 算法的第 t 代个体知识

库, N 是当前种群和个体知识库中的个体总数。EIHLO 算法通过三种学习操作, 产生一个新的候选解, 同时, 利用更新运算的方法, 在个人知识库中存储具有较优适合度的个体信息 IKD 中, 则 EIHLO 算法的个体知识库序列变换用任意状态表示为:

$$x(t) \xrightarrow{\text{三个学习算子}} x(t+1) \xrightarrow{IKD\text{更新操作}} IKD(t+1) \quad (2-13)$$

对于 EIHLO 算法, 每个比特位取值具有两种情况^[51], 若采用 Q 位比特编码方式来表示变量, 对变量的字符串组成情况为 2^Q , 若一组解集个数为 L , 则一组解集的取值情况为 $2^{Q_1} \times 2^{Q_2} \times \dots \times 2^{Q_L}$ 即 2^M 。种群为 N 的 EIHLO 算法, 个体知识库 IKD 的空间为 $N \times 2^M$ 。

EIHLO 算法 IKD 状态从 t 代更新到 $(t+1)$ 代是随机状态的转移矩阵 $IKD(t) \rightarrow IKD(t+1)$, $IKD(t+1)$ 个体知识库的状态仅与上一代 $IKD(t)$ 有关, 因此 EIHLO 的个体知识库序列是有限随机马尔可夫链, 完证。

令 S 表示测试函数的解空间, $f(x)$ 表示测试函数, $f^* = \max\{f(x) | x \in S\}$ 是在探索解过程中, 取最佳的适应值, 令 $IKD^* = \{IKD | \max(f(IKD)) = f^*, \forall IKD \in S\}$ 。

定义 2^[52]: $\{IKD(t), t \geq 0\}$ 是解空间上的随机序列, $\forall S_0 \in S$, S_0 是初始解, 若 IKD 在迭代数 t 趋于无穷大时满足公式表示为:

$$\lim_{t \rightarrow \infty} P\{IKD(t) \in IKD^* | IKD(0) = S_0\} = 1 \quad (2-14)$$

则称随机序列 $\{IKD(t), t \geq 0\}$ 以概 1 收敛于全局最优。

令 EIHLO 算法 t 代的收敛概率表示 p^t 表 $P\{IKD(t) \in IKD^* | IKD(0) = S_0\}$, 则 $P^t = \sum_{i \in IKD^*} P\{IKD(t) = i | IKD(0) = S_0\}$ 。第 t 代的第 i 个体收敛概率 $p_i(t)$ 表示 $P\{IKD(t) = i | IKD(0) = S_0\}$, 则概率表示为:

$$P^t = \sum_{i \in IKD^*} p_i(t) \quad (2-15)$$

$P_{ij}(t) = P\{IKD(t) = j | IKD(0) = i\}$, 在 EIHLO 算法的 IKD 更新操作下, 则得出两个特殊方程式表示为:

$$\text{当 } i \in IKD^*, j \notin IKD^*, P_{ij}(t) = 0 \quad (2-16)$$

$$\text{当 } i \in IKD^*, j \in IKD^*, P_{ij}(t) = 1 \quad (2-17)$$

定理 2: 增强勤奋人类学习优化算法 (EIHLO) 以概率 1 收敛于全局最优。

证明: 根据已知 $\sum_{j \notin IKD^*} P_{ij}(t) + \sum_{j \in IKD^*} P_{ij}(t) = 1$, 可得算法第 t 代收敛概率 P_1^t 的关系式表示为:

$$P_1^t = \sum_{i \in IKD^*} P_i(t) \times \left(\sum_{j \notin IKD^*} P_{ij}(t) + \sum_{j \in IKD^*} P_{ij}(t) \right) \quad (2-18)$$

整理上式得到关系式表示为:

$$P_1^t = \sum_{i \in IKD^*} \sum_{j \notin IKD^*} P_i(t) P_{ij}(t) + \sum_{i \in IKD^*} \sum_{j \in IKD^*} P_i(t) P_{ij}(t) \quad (2-19)$$

将 $P_{ij}(t) = 0$, 代入可得:

$$\sum_{i \in IKD^*} \sum_{j \notin IKD^*} P_i(t) P_{ij}(t) = 0 \quad (2-20)$$

将式(2.20)带入式(2.19)中对其进行进一步化简, 可得:

$$P_1^t = \sum_{i \in IKD^*} \sum_{j \in IKD^*} P_i(t) P_{ij}(t) \quad (2-21)$$

由定理 1 可知, EIHLO 算法的个体知识库序列是有限随机马尔科夫链。因此, 第 $(t+1)$ 代收敛概率的表示为:

$$P_1^{t+1} = \sum_{i \in IKD} \sum_{j \in IKD} P_i(t) P_{ij}(t) + \sum_{i \in IKD} \sum_{j \in IKD} P_i(t) P_{ij}(t) \quad (2-22)$$

将式 (2.21) 带入式 (2.22) 中可得算法的第 t 、 $t+1$ 代收敛概率 p_1^t 和 p_1^{t+1} 的公式表示为:

$$P_1^{t+1} = P_1^t + \sum_{i \notin IKD^*} \sum_{j \in IKD^*} P_i(t) P_{ij}(t) > P_1^t \quad (2-23)$$

同理可得:

$$1 \geq P_1^{t+1} \geq P_1^t \geq P_1^{t-1} \geq P_1^{t-2} \dots \quad (2-24)$$

由上式可知, 算法第 t 代($t \rightarrow \infty$)的收敛概率 P_1^t 可表示为:

$$\lim_{t \rightarrow +\infty} P_1^t = 1 \quad (2-25)$$

因此, 可以得出增强勤奋人类学习优化算法 (EIHLO) 以概率 1 收敛于全局最优, 定理 2 证毕。

2.4 函数极值优化仿真

在本节中，为验证 EIHLO 的有效性和可行性，测试集中常见单峰函数、多峰函数及离散函数作为测试函数，分别与 HLO、HLOPSO^[53]算法进行了比较分析。函数介绍如表 2-1 所示，选取 15 个具有不同特征的 CEC2005 基准函数，每个函数都具有不同的特征，F1~F7 为单峰、F8~F12 多峰、F13~F15 为离散型。为避免偏差，对所有算法保持公平。本章仿真在 Intel Pentium Dual 2.50GHz 处理器、4.00G RAM 和 MATLAB(R2021a)的软件上进行。所有算法的种群设为是 60，迭代次数为 200 且每个算法在测试函数上独立运行多次然后求平均值。用最优值、均值和方差来评估算法的性能。

表 2-1 基准测试函数

函数	公式	最小值	类型	维度
F1	$\sum_{i=1}^N x_i^2$	0	Unimodal	3/30
F2	$\sum_{i=1}^N x_i + \prod_{i=1}^N x_i $	0	Unimodal	3/30
F3	$\sum_{i=1}^N (\sum_{j=1}^i x_j)^2$	0	Unimodal	3/30
F4	$\max \{ x_i , 1 \leq i \leq N \}$	0	Unimodal	3/30
F5	$\sum_{i=1}^{N-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	0	Unimodal	3/30
F6	$\sum_{i=1}^N ([x_i + 0.5])^2$	0	Unimodal	3/30
F7	$\sum_{i=1}^N ix_i^4 + \text{random}[0,1)$	0	Unimodal	3/30
F8	$\sum_{i=1}^N -x_i \sin(\sqrt{ x_i })$	-12567	Multimodal	3/30
F9	$\sum_{i=1}^N [x_i^2 - 10 \cos(2\pi x_i) + 10]$	0	Multimodal	3/30
F10	$-20 \exp(-0.2 \sqrt{1/N \sum_{i=1}^N x_i^2}) - \exp(1/N \sum_{i=1}^N \cos(2\pi x_i)) + 20 + e$	0	Multimodal	3/30
F11	$1/4000 \sum_{i=1}^N x_i^2 - \prod_{i=1}^N \cos(x_i/\sqrt{i}) + 1$	0	Multimodal	3/30

F12	$\frac{\pi}{N} \left\{ 10 \sin^2(\pi y_i) + \sum_{i=1}^{N-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_N - 1)^2 \right\}$ $+ \sum_{i=1}^{N-1} u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4}, u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a \leq x_i \leq a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	0	Multimodal	3/30
F13	$0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^{N-1} (x_i - 1)^2 [1 + \sin^2(3\pi x_{i+1})] \right.$ $\left. + (x_N - 1)^2 [1 + \sin^2(2\pi x_N)] \right\} + \sum_{i=1}^N u(x_i, 5, 100, 4)$	0	Fixed	3/30
F14	$\sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	0.000308	Fixed	4/30
F15	$[1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3(x_1 + x_2)^2 - 14x)] \times [30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	3	Fixed	2/30

2.4.1 针对低维基准函数

低维函数的结果在表 2-2 中给出，最优结果用粗体表示以便于识别。EIHLO 在 15 个函数中获得了 13 个最佳数值结果，优于其他对比算法，其余 2 个函数 F8 的最优值相同，函数 F15 中是最佳方差数值。具体而言，EIHLO 的方差仅劣于 F8 上的 HLO。因此，可以得出所改进的算法具有有效性和可行性，同时具有更高的稳定性和鲁棒性并在低维基准测试函数上实现了最佳性能。

表 2-2 HLO、HLOPSO、EIHLO 在低维基准函数的结果对比

函数	衡量标准	HLO	HLOPSO	EIHLO
F1	最优值	5.04E-02	1.74E-02	2.17E-03
	均值	4.22E+00	6.90E-02	4.57E-02
	方差	4.17E+00	4.46E-02	4.42E-02
F2	最优值	2.32E-02	1.40E-02	1.12E-02
	均值	5.76E-01	4.87E-02	2.51E-02
	方差	6.39E-01	2.85E-02	1.40E-02
F3	最优值	2.90E+00	2.46E-01	8.61E-03
	均值	7.21E+01	1.40E+00	2.26E-01
	方差	7.45E+01	1.14E+00	1.67E-01
F4	最优值	5.12E-01	1.89E-01	5.61E-02
	均值	3.96E+00	5.08E-01	1.50E-01
	方差	4.10E+00	2.13E-01	1.11E-01
F5	最优值	1.01E+00	2.13E-01	1.67E-01
	均值	8.39E+00	1.47E+00	7.39E-01
	方差	7.33E+00	8.31E-01	5.46E-01

F6	最优值	3.34E-01	4.23E-02	5.01E-03
	均值	1.05E+01	2.75E-01	1.07E-01
	方差	1.42E+01	1.88E-01	1.26E-01
F7	最优值	2.88E-02	1.50E-03	7.66E-05
	均值	6.31E-02	4.92E-03	1.58E-03
	方差	3.73E-02	3.76E-03	1.17E-03
F8	最优值	-1.21E+03	-1.26E+03	-1.26E+03
	均值	-1.01E+03	-1.24E+03	-1.25E+03
	方差	1.40E+02	1.64E+01	1.53E+01
F9	最优值	1.04E+00	3.20E-01	1.34E-02
	均值	7.26E+00	7.43E-01	2.50E-01
	方差	4.01E+00	3.41E-01	1.88E-01
F10	最优值	2.12E+00	5.38E-01	1.22E-01
	均值	2.79E+00	1.07E+00	4.36E-01
	方差	2.02E+00	4.73E-01	2.56E-01
F11	最优值	4.79E-01	8.35E-02	6.82E-02
	均值	3.75E+00	1.52E-01	1.03E-01
	方差	6.75E+00	4.84E-02	2.80E-02
F12	最优值	4.96E-01	1.32E-02	4.10E-04
	均值	3.14E+00	7.13E-02	2.49E-02
	方差	2.52E+00	5.67E-02	2.67E-02
F13	最优值	3.02E-01	2.08E-02	5.37E-03
	均值	4.31E-01	4.53E-02	1.64E-02
	方差	2.04E-01	2.28E-02	8.34E-03
F14	最优值	1.39E-03	1.11E-03	7.56E-04
	均值	1.84E-01	1.90E-03	9.46E-04
	方差	4.18E-01	6.33E-04	2.05E-04
F15	最优值	3.00E+00	3.00E+00	3.00E+00
	均值	3.44E+01	3.00E+00	3.00E+00
	方差	2.93E+01	3.12E-03	2.11E-03

2.4.2 针对高维基准函数

为了进一步证明算法的有效性,对于高维函数进行测试,测试结果在表 2-3 中给出,在求解过于复杂的问题时,由于受到计算复杂度、搜索空间、局部最优陷阱等影响,所有算法的优化性能都会降低,但同种条件 EIHLO 相对于另外两种算法仍然存在优势。具体结果如表 2-3 所示,最优的结果用粗体表示。EIHLO 在 15 个函数中获得了 13 个最优数值,最优结果全都优于 HLO,仅次 F13、F15 次于 HLOPSO。在 15 个函数中均值都高于 HLO,仅 F7 低于 HLOPSO,其余都是最优。方差在 F3、F6、F18 上低于 HLO,在 F11 低于 HLOPSO。根据表 2-3 可以得出 EIHLO 在高维基准函数上同样有效和可行。

表 2-3 HLO、HLOPSO、EIHLO 在高维基准函数的结果对比

函数	衡量标准	HLO	HLOPSO	EIHLO
F1	最优值	2.48E+04	2.60E+04	2.05E+04
	均值	4.28E+04	3.25E+04	2.83E+04
	方差	1.13E+04	4.81E+03	3.95E+03
F2	最优值	6.41E+01	6.46E+01	5.08E+01
	均值	1.28E+02	7.71E+01	6.31E+01
	方差	1.09E+02	1.31E+01	8.89E+00
F3	最优值	4.55E+04	3.51E+04	2.56E+04
	均值	7.63E+04	3.96E+04	3.18E+04
	方差	1.60E+04	3.46E+03	3.38E+03
F4	最优值	7.93E+01	5.98E+01	5.63E+01
	均值	9.05E+01	6.76E+01	6.25E+01
	方差	4.56E+00	4.46E+00	3.33E+00
F5	最优值	4.64E+07	2.80E+07	1.82E+07
	均值	1.14E+08	4.59E+07	3.13E+07
	方差	4.86E+07	9.28E+06	8.39E+06
F6	最优值	3.53E+04	2.16E+04	1.71E+04
	均值	3.94E+04	3.00E+04	2.40E+04
	方差	3.26E+03	5.15E+03	4.79E+03
F7	最优值	2.62E+01	1.25E+01	5.38E-01
	均值	5.51E+01	2.17E+01	1.84E+00
	方差	2.01E+01	6.63E+00	7.15E-01
F8	最优值	-5.17E+03	-5.86E+03	-5.98E+03
	均值	-3.68E+03	-5.12E+03	-5.33E+03
	方差	2.68E+03	3.83E+02	4.09E+02
F9	最优值	2.26E+02	1.88E+02	1.69E+02
	均值	2.86E+02	2.06E+02	1.89E+02
	方差	4.31E+01	1.23E+01	1.09E+01
F10	最优值	1.86E+01	1.69E+01	1.69E+01
	均值	1.93E+01	1.86E+01	1.81E+01
	方差	4.28E-01	6.17E-01	5.10E-01
F11	最优值	3.25E+02	2.37E+02	1.84E+02
	均值	3.90E+02	2.71E+02	2.33E+02
	方差	6.42E+01	2.13E+01	2.74E+01
F12	最优值	4.65E+07	4.06E+07	1.76E+07
	均值	1.91E+08	6.33E+07	3.55E+07
	方差	1.21E+08	1.70E+07	1.28E+07
F13	最优值	2.19E+08	1.22E+08	7.58E+07
	均值	5.42E+08	1.84E+08	1.29E+08
	方差	2.33E+08	5.21E+07	2.66E+07
F14	最优值	6.19E-03	9.26E-04	7.04E-04
	均值	1.81E+00	2.45E-03	1.25E-03
	方差	2.22E+00	1.18E-03	4.32E-04


F15	最优值	4.54E+00	3.00E+00	3.00E+00
	均值	1.56E+02	3.13E+00	3.02E+00
	方差	1.47E+02	9.22E-02	3.21E-02

综上所述，仿真结果表明，EIHLO 算法不仅在低维基准测试函数上实现了最佳性能，展现了较高的稳定性和鲁棒性。在高维基准测试函数上同样取得的最优效果，证明了该算法的有效性和可行性。EIHLO 算法为优化问题的求解提供了一种高效且可靠的解决方案，具有广泛的应用潜力。


2.4.3 测试函数图像及算法的收敛曲线

为了使仿真效果更加直观，绘制出所有函数的二维形状图形；同时展示出不同维度下各算法收敛曲线。如图 2-5 所示，可以看出低维度下 EIHLO、HLO、HLOPSO 的曲线收敛情况。在单峰测试函数中(F1~F7)中，除 F3 外收敛速度均快于其他算法，说明概率参数的改进可以提高搜索效率，增强寻优能力。从图中还可以看出收敛精度与对比算法相比大幅度提高，改进算法是可行且有效的。


如图 2-6 所示 F8~F13 的多峰测试函数，用于验证算法的抗干扰能力。图中可以看出，在多峰测试函数中，除 F8 和 F13 外，对于 F9、F10、F11、F12 这几个测试函数，EIHLO 表现明显优于另外两种算法。意味着在复杂多峰的环境下，改进算法能够更好地应对干扰，稳定地寻找最优解。如图 2-7 所示固定维数下的测试函数，对于函数 F14，EIHLO 的收敛速度及寻优精度表现较为优秀。而对于函数 F15，虽然其收敛速度并没有明显优于 HLOPSO，但优于 HLO。图像对比和分析结果，为 EIHLO 的性能提供了全面且直观的依据。




(a)各算法函数 F1 收敛曲线




(b)各算法函数 F2 收敛曲线




(c)各算法函数 F3 收敛曲线




(d)各算法函数 F4 收敛曲线



(e)各算法函数 F5 收敛曲线




(f)各算法函数 F6 收敛曲线




(g)各算法函数 F7 收敛曲线


图 2-5 单峰测试函数图像及算法收敛图




(a)各算法函数 F8 收敛曲线




(b)各算法函数 F9 收敛曲线




(c)各算法函数 F10 收敛曲线



(d)各算法函数 F11 收敛曲线




(e)各算法函数 F12 收敛曲线




(f)各算法函数 F13 收敛曲线

图 2-6 多峰测试函数图像及算法收敛图



(a)各算法函数 F14 收敛曲线



(b)各算法函数 F15 收敛曲线

图 2-7 固定维数测试函数图像及算法收敛图

2.5 EIHLO 的路径规划仿真

2.5.1 路径规划实现流程

本章路径规划算法核心思想是通过初始化算法参数、构建环境地图以及结合多种优化策略来搜索最优路径。首先，对算法初始化阶段需要对各项参数进行设置，包括种群规模、最大迭代次数、学习因子等。基于栅格法构建环境地图，将障碍物、起点和目标点的位置信息映射到栅格中。接着，随机生成一条较优路径作为初始解，并将所有个体从起点出发，开始探索可行路径。为了确保路径的连续性和避免重复访问，起点会被加入禁忌列表。在路径搜索过程中，算法采用轮

盘赌法选择机制随机选择下一节点,同时结合个体学习算子和社会学习算子来优化搜索方向。每选择一个节点后,该节点会被加入禁忌列表,以避免路径重复。随后,算法会判断当前路径是否达到目标点;如果到达目标点,则进入下一步骤;如果未到达,则继续通过轮盘赌法选择机制和个体学习策略选择下一节点,并逐步扩展路径。

在迭代过程中, EIHLO 会动态更新 IKD 和 SKD。通过不断更新这两个知识库,能够更高效地搜索,避免陷入局部最优。迭代结束后,算法会判断是否达到最大迭代次数;如果达到,则输出当前最优路径,反之,则继续搜索更优路径。EIHLO 路径规划流程图如图 2-8 所示。





图 2-8 EIHLO 算法路径规划流程图

2.5.2 仿真及结果分析


为了验证EIHLO的有效性,在对环境建立栅格地图的基础上进行了如下两组路径规划仿真: 20×20 、 30×30 仿真环境下,将EIHLO、GA、HLOPSO进行对比。并且选取栅格图中左下角为起点,右上角为终点,在GA中交叉概率选取0.8,变异概率取为0.05。HLOPSO中概率参数 $pr = 5.0 / m$ 、 $pi = 0.85 + 2.0 / m$ 。改进改进算法的概率参数如上文所示,采用HLOPSO中的取值 $pr_{\max} = 100 / m$ 、 $pr_{\min} = 1 / m$ 、 $pi_{\max} = 0.9 + 1 / m$ 、 $pi_{\min} = 0.8 + 1 / m$ 。三种算法的种群数量均为50、迭代次数为200次。为了确保仿真结果的准确性与可靠性,为避免单个试验引起的误差,在不同的环境图上,进行了多个模拟试验,计算了试验结果的平均值。仿真环境MATLAB R2019,仿真运行PC操作系统为Windows2010,处理器为Intel Corei5-7200U CPU。

1) 20×20 仿真环境


在 20×20 环境模型下,将 EIHLO、GA、HLOPSO 算法进行对比仿真。比较不同算法路径规划的路径长度、转弯次数、程序运行时间与障碍物接触次数。通过对四个关键指标的比较分析,全面、客观地评估 EIHLO、GA、HLOPSO 这三种算法在路径规划方面的性能表现。为实际应用中算法的选择提供科学、可靠的依据。各算法的仿真结果如图 2-9 所示,图(a)表示 GA 的路径规划;图(b)表示 HLOPSO 的路径规划;图(c)表示 EIHLO 路径规划。三种算法的收敛曲线如图 2-10 所示;仿真结果对比见表 2-4。



(a)GA 路径规划



(b)HLOPSO 路径规划



(c) EIHLO 路径规划

图 2-9 三种算法规划路径图

从图 2-9 中可以看到 GA 算法规划的路径规划不仅从障碍物中间通过, 增加发生碰撞的可能具有一定的危险性, 而且在规划的过程中多次拐弯, 规划混乱。HLOPSO 在路径规划时优于 GA 算法, 但仍存在拐弯次数多, 绕路等情况存在。从图中明显看出, 相比于其他两种算法, EIHLO 的规划路径长度最短, 且拐弯次数最少, 与障碍物接触次数最少, 避免了发生碰撞的可能。因此, 在 20×20 的环境中, EIHLO 可以规划出更佳的路径, 使其更符合现实工作环境。




图 2-10 三种算法的收敛曲线图

从图 2-10 中可以看出, EIHLO 在收敛速度和优化性能方面均表现一定优势。EIHLO 在迭代初期收敛趋势较快, 能在较少的迭代次数内迅速寻到最优值, 较强的全局搜索能力和高效的优化效率。相比之下, GA 和 HLOPSO 在相同迭代次数下的收敛速度稍慢, 且优化结果与 EIHLO 存在一定差距。EIHLO 最终寻找到的最优值明显优于 GA 和 HLOPSO。


结合表 2-4, EIHLO 最优路径长度比 GA 减少了 19.68 %, 比 HLOPSO 减少了 6.13%; EIHLO 在拐弯次数上比 GA 减少了 33.33%, 且优于 HLOPSO, 拐弯次数减少了 20%; 稳定迭代次数比 GA 减少了 42.10%, 比 HLOPSO 减少 56.00%; GA 收敛曲线的变化范围很大, 达稳态所需的时间比较长, EIHLO 在迭代稳定时间方面相较于 GA 减少了 37.82%, EIHLO 迭代稳定时间稍逊于 HLOPSO。EIHLO 在路径长度、迭代次数和转弯次数上都要优于 GA、HLOPSO。

表 2-4 20×20 地图规模仿真结果对比


最优路径各项指标	GA	HLOPSO	EIHLO
路径长度/m	36.93	31.60	29.66
转弯次数	12	10	8
迭代稳定次数	21	27	12
程序运行时间/s	1.56	0.85	0.97

2) 30×30 仿真环境


为进一步验证 EIHLO 可靠性, 增加地图环境复杂度, 在 30×30 环境模型下仿真。同样将 EIHLO、GA、HLOPSO 进行对比仿真。比较它们路径长度、转弯次数、程序运行的时间与障碍物接触的次数。三种算法仿真结果如 2-11 所示, 图(a)表示 GA 的路径规划; 图(b)表示 HLOPSO 的路径规划; 图(c)表示 EIHLO 路径规划。三种算法的收敛曲线如图 2-12 所示; 仿真结果对比见表 2-5。



(a)GA 路径规划



(b)HLOPSO 路径规划



(c)EIHLO 路径规划

图 2-11 三种算法的路径规划图

从图 2-12 可以看出 EIHLO 在收敛速度和优化性能方面均表现出优势。EIHLO 在迭代初期便展现出较快的收敛趋势,能够在较少的迭代次数内迅速逼近最优值,这表明其具有较强的全局搜索能力和高效的优化效率。相比之下,GA 和 HLOPSO 在相同迭代次数下的收敛速度较慢,且其优化结果与改进算法存在差距。可以得到,在更为复杂的 30×30 地图环境模型中, EIHLO 路径规划时的收敛速度和优化性能方面仍然优于 GA 和 HLOPSO。




图 2-12 三种算法的收敛曲线图

仿真结果如表 2-5 所示, EIHLO 最优路径长度比基本 GA 减少了 29.89%, 同时比 HLOPSO 减少了 17.54%; EIHLO 在拐弯次数上比 GA 减少了 25%, 且优于 HLOPSO, 拐弯次数减少了 16.67%; 稳定迭代次数比 GA 减少 13.74%, 比 HLOPSO 减少 57.6%; EIHLO 在迭代稳定时间方面相较于比 HLOPSO 稍逊一些, 而相对于 GA 算法具有较大幅度的提升减少了 58.8%。EIHLO 在路径长度、迭代次数和转弯次数上都要优于 GA, 仅在迭代稳定次数逊于 HLOPSO。由此可见, EIHLO 在 30×30 的环境模型下仍然具有很强的优越性。

表 2-5 30×30 地图规模仿真结果对比

最优路径各项指标	GA	HLOPSO	EIHLO
路径长度/m	74.87	63.66	52.49
转弯次数	20	18	15
迭代稳定次数	21	43	18
程序运行时间/s	3.01	1.11	1.24

通过两种不同尺度的栅格地图模拟试验, 发现 EIHLO 在满足搜索全局最优解的同时, 仍能快速收敛, 并且在几次迭代后趋于稳定; 而其他两类算法在初始迭代时极不稳定, 收敛较慢。因此, 对最佳路线的各个方面的性能进行全面的评估, EIHLO 优势明显。

2.6 本章小结

本章探讨了一种增强人类学习优化算法(EIHLO), 用于解决 AGV 的路径规划问题。首先, 改进参数 pr 和 pi 的概率, 调整它们的数值变化来控制各个算子的执行概率, 寻找更多最优解, 提高了 AGV 的路径优化能力。其次, 引入 PSO 算法改进 IKD 和 SKD 的更新操作, 从而有效地提高了路径的搜索效率, 加快了算法的收敛速度。并改进的惯性权重系数, 提高算法的整体优化能力, 不易陷入局部最优。最后, 将其应用于测试函数测试、不同环境下 AGV 路径规划。

第3章 基于 EIHLO 和 DWA 的单 AGV 局部路径规划

3.1 DWA 的改进研究

动态窗口法是能够高效完成局部路径实时动态避障的算法^[54-55]。该方法的基本思路是把路径规划问题化为一个在速度矢量空间中的约束问题。通过建立 AGV 运动模型，将 AGV 的位置约束转化为速度约束，得到 AGV 运动状态下的角速度与线速度的范围，速度范围构成了一个速度窗口。随后通过对窗口内的速度及其加速度的无碰撞约束，利用这些速度集模拟出轨迹。最后利用评价函数对所有轨迹进行评估，选择其中最佳轨迹。重复这一过程，建立一个新的窗口，并以迭代的方式继续循环，便得到移动速度窗口。AGV 运动学模型如图 3-1 所示。




图 3-1 运动学模型

3.1.1 AGV 运动学模型

将 AGV 整个的运动过程全部分割成微小的时间节点，并将时间间隔标记为 Δt ，AGV 的运动模型表示为：

$$\begin{aligned} x_{t+\Delta t} &= x_t + v\Delta t \cos(\theta_t) \\ y_{t+\Delta t} &= y_t + v\Delta t \sin(\theta_t) \\ \theta_{t+\Delta t} &= \theta_t + \omega\Delta t \end{aligned} \quad (3-1)$$

其中， v 、 ω 包括线速度与角速度， (x_t, y_t) 表示当前位置， $(x_{t+\Delta t}, y_{t+\Delta t})$ 表示下一时刻位置， θ_t 为当前运动方向角度， $\theta_{t+\Delta t}$ 表示下一时刻运动方向角度。 $\sin(\theta_t)$ 、 $\cos(\theta_t)$ 表示三角函数值。

3.1.2 DWA 速度采样

AGV 在速度空间中速度受到各种因素的限制，如物理极限、环境障碍、运动稳定性等多方面因素的限制，DWA 将 AGV 的避障问题简化为具有相对限制的优化问题，为 AGV 规划出既安全又高效的行进策略。

1) 最大速度范围

AGV 受到最大最小线速度和角速度约束， V_s 为 AGV 能够到达的所有矢量速度的集合。速度约束范围可表示为：

$$V_s = \{v \in [v_{\min}, v_{\max}], \omega \in [\omega_{\min}, \omega_{\max}]\} \quad (3-2)$$

其中， V_s 表示速度采样空间， v 、 ω 表示线速度和角速度， $v_{\min}$ 、 $v_{\max}$ 分别表示线速度的最小值与最大值， $\omega_{\max}$ 、 $\omega_{\min}$ 分别表示 AGV 角速度最大值与最小值。

2) 电机性能的影响

加速和减速有上限和下限，只有当最大加速或者最大减速能够在某一段时间内达到速度，才会出现在动态窗口，受到加减速影响最大和最小速度范围表示为：

$$V_d = \{(v, \omega) | v \in [v_n - a_v^{\min} t, v_n + a_v^{\max} t] \wedge \omega \in [\omega_n - a_w^{\min} t, \omega_n + a_w^{\max} t]\} \quad (3-3)$$

其中， v_n 、 ω_n 分别表示此时的线速度、角速度； $a_v^{\min}$ 、 $a_w^{\min}$ 分别表示最小线速度与角速度； $a_v^{\max}$ 、 $a_w^{\max}$ 分别表示最大的线加速度和角加速度。

3) 障碍物影响

为使 AGV 在运动时与环境中的障碍物具有足够的安全距离，即能在碰到障碍物前停下，在最大减速度的条件下，速度满足条件表示为：

$$V_a = \{(v, \omega) | v \in [v_{\min}, \sqrt{2dis(v, \omega) * a_v^{\max}}] \wedge \omega \in [\omega_{\min}, \sqrt{2dis(v, \omega) * a_w^{\max}}]\} \quad (3-4)$$

其中， $dist(v, \omega)$ 表示此速度下该轨迹与障碍物之间的最短距离。以上几种对 AGV 的影响将其速度限制在一定的范围内称为动态窗口，速度集其表示为：

$$V_r = V_s \cap V_d \cap V_a \quad (3-5)$$

图 3-2 中该长方形的长度与宽度是根据其最大直线速度与最小角速度数值决定的。整个长方形分为安全区和非安全区，其中红色部分是不安全区，在长方形的方框中，白色是 AGV 的理论速度区间，逐层叠加以现实约束。剔除与障碍物预测轨迹重叠的“红色禁区”后，剩余的绿色区域为最终确定的动态窗口。




图 3-2 动态窗口示意图

3.1.3 评价函数

在传统的 DWA 算法中，当全局规划路径上有障碍物时，AGV 往往会过于靠近障碍物以达到全局规划的路径或目标点，这就必然会造成 AGV 和障碍物间的最小避障距离不能满足要求。随着时间的增加，AGV 与障碍物间动态间隙持续缩减，导致避障决策的有效缓冲时间呈非线性递减，给 AGV 实时运动规划增加危险。一旦障碍物空间分布密度的提升，由于 AGV 无法及时规避障碍物，容易陷入造成 AGV 死机。所以在评价函数中添加一个角度评价子函数，用于评估 AGV 与障碍物之间夹角，以提高 AGV 运动的稳定性和路径的平滑性。如果 AGV 与障碍物的最短距离超过设定的二分之一时，那么 AGV 与障碍物直接的夹角设为 25° 。距离小于设置安全距离的二分之一时，直接求出两者之间的夹角。角评价函数公式表示为：

$$dtheta = \begin{cases} 25^\circ & dist > distcs / 2 \\ \frac{|\theta_{job} - \theta_{zt}|}{10} & dist < distcs / 2 \end{cases} \quad (3-6)$$

其中， $dtheta$ 为角评价函数，保证 AGV 与障碍物直接的存在一定偏向角，避免夹角过小发生碰撞， θ_{job} 表示 AGV 当前位置指向障碍物的朝向角， θ_{zt} 表示当前 AGV 的姿态角度。AGV 与障碍物的距离越近对 $dtheta$ 修正越小。 $dist$ 表示 AGV 的当前位置，距离最近的障碍物的位置。 $distcs$ 表示设置的安全距离。经过运动学模型和多种速度约束后，AGV 运动学模型能够预测出多条轨迹，根据评价函

数进行轨迹评价，筛选出最佳的轨迹。改进的评价函数表示为：

$$G(v, w) = \sigma[\alpha \cdot heading(v, w) + \beta \cdot distgo(v, w) + \gamma \cdot velocity(v, w) + \psi \cdot dTheta] \quad (3-7)$$

其中， σ 表示归一化参数， $G(v, w)$ 为模拟轨迹评价函数， $heading(v, w)$ 为方位角评价函数，保证 AGV 朝着目标点运动，AGV 运动方向与目标方向偏差越小，其值越大； $dist(v, w)$ 为 AGV 与障碍物的最近距离，其值越大越安全，保证 AGV 避开障碍物； $velocity(v, w)$ 为当前速度大小的评价函数，用于评估 AGV 当前速度大小与目标速度之间的差异程度，保证 AGV 以最大的速度运动； α 、 β 、 γ 表示各项加权系数。

3.1.4 动态改变权重系数策略

在传统的 DWA 算法中，原评价函数的标准相对独立，评价函数的权重系数通常被预设为固定值，静态参数设置会带来的局限性，随着环境变化，固定的权重比例已经难以满足不同场景的优化需求，故利用恒定的权重系数进行移动 AGV 局部路径规划，可能会导致路径规划成功率较低、路径安全性降低、路径转弯过多，基于上述存在的问题，研究一种动态改变角速度、速度权重来解决此类问题，改进后的算法具有更好的环境适应能力，规划路径质量更高，同时能有效的避开环境周围中的障碍物，公式表示为：


$$\begin{aligned} \gamma &= 0.1 + 0.1 \cdot (1 / distgo) \\ \psi &= 0.02 + 0.1 \cdot (1 / densgo) \end{aligned} \quad (3-8)$$

其中， $densgo$ 表示障碍物密集程度，障碍物越密集权重 ψ 越大。 $distgo$ 表示 AGV 与目标点之间距离，AGV 离目标越近，权重 γ 越大，保证 AGV 朝着目标运动。


3.2 EIHLO 和 DWA 的混合算法

3.2.1 改进 DWA 局部路径规划仿真


利用栅格法建立一个 10×10 二维静态网格地图，设置路径规划起点(0,0)，终点(9.5,9)。黑色方格表示障碍物，通过对比仿真验证改进 DWA 算法与传统算法的性能差异，比较两种算法规划路径平滑性、避障成功率、规划时间、适应不同环境的能力、转弯次数。在图3-3中，图(a)、图(c)、图(e)、图(g)、图(i)为传统 DWA 算法，图(b)、图(d)、图(f)、图(h)、图(j)为改进 DWA 算法，效果如图3-3所示。




(a)传统DWA算法




(b)改进DWA算法




(c)传统DWA算法




(d)改进DDA算法




(e)传统DWA算法



(f)改进DWA算法



(g)传统DWA算法



(h)改进DWA算法




图 3-3 改进后的 DWA 与传统算法对比图

图 3-3(a)传统 DWA 算法的路径规划不能避开“陷进”导致死循环，而图(b)很好的避开陷阱。传统 DWA 算法在进行图(c)路径规划时后期远离目标点，增加路径成本，路径规划质量较差，图(d)则在避开障碍物的同时始终朝着目标点前进。图(e)与图(g)都是无法避开障碍物，路径规划效果差。图(f)与图(h)则避开了障碍物并且朝向目标前进。通过前、后算法的对比，验证改进 DWA 算法在复杂障碍物的环境中通行能力，在面对复杂的动态环境时更能体现出改进 DWA 算法的优越性，表 3-1 分别为图 3-3(i)与图 3-3(j)的运行行时间、总路程和转弯次数的对比。

表 3-1 改进前后对比

算法	路径长度/m	规划时间/s	转弯次数
传统 DWA 算法	19.522	55.361	12
改进 DWA 算法	16.425	31.981	7

从表 3-1 中可以看出改进后的 DWA 算法的路径长度比传统 DWA 算法减少 15.86%。规划时间比传统 DWA 算法减少 42.23%。转弯次数比传统 DWA 算法 41.67%。证明改进的 DWA 算法具有可行性。

3.2.2 混合算法流程

本文通过 EIHLO 算法可以进行全局路径规划，但是无法避免环境中出现的未知障碍物。传统 DWA 具有良好的避障能力，但是该算法在应用过程中无法保证全局最优，使得 AGV 在运行时容易陷入局部极值。因此，选择将 EIHLO 算法与 DWA 混合，以 EIHLO 规划的全局路径关键转折点为 DWA 的局部目标点进行局部路径规划，在保证动态规划路径全局最优前提下，实现对障碍物的实时规避，混合算法的流程如图 3-4 所示。




图 3-4 混合算法流程图

3.2.3 混合算法仿真及分析


首先建立 20×20 规模复杂地图, 图 3-5 中黄色方块为全局路径规划起点, 绿色五角星为终点, 黑色三角形与黑色正方形分别为移动障碍物的起始点。黑色线为全局路径规划路径, 蓝色为改进 DWA 算法规划路径, 红色线动态障碍物规划路径, 白色代表可行区域, 红色叉号表示全局路径关键节点, 起点设为栅格 (2,2) 内用黄色方块表示, 终点在 (19,19) 用绿色的五角星表示。仿真采用 MATLAB


R2021a 软件, 仿真环境为 Windows11 64 位; 处理器 Intel(R) Core(TM) i7-12700; 内存 16 GB。仿真所采取的参数如表 3-2:

表 3-2 算法参数取值


参数	数值	参数	数值
种群数量	50	加速度(m/s ²)	0.5
迭代次数	50	旋转加速度(rad/s ²)	$\pi / 20$
认知系数	1.5	最高线速度(m/s)	0.5
社会学习系数	1.5	最高角速度(rad/s)	$\pi / 30$
动态障碍物速度(m/s)	0.056	安全距离(m)	0.5
最大权重	1	AGV 半径(m)	0.5
最大权重	0.4	单位时间(s)	0.2
线速度分辨率(m/s)	0.05	方位角评价系数	0.1
角速度分辨率(rad/s)	$\pi / 30$	速度评价系数	0.2

在 20×20 栅格地图中, 加入一种以均匀速度移动的动态障碍, 使得其运动轨迹和全局规划路线有交集, 并且在全局路径的关键点处增加了一些静止障碍物。图 3-5(a)表示 AGV 按照 EIHLO 的全局最优路径前进, AGV 在前行时预先检测到动态障碍物, 利用改进的 DWA 算法及时的以安全间距绕过动态障碍物, 并以 EIHLO 路径关键点为临时子目标继续行驶。图 3-5(b)表示 AGV 成功躲避第一个随机静止障碍物后返回全局最优路径, 再次以全局最优路径关键点为子目标点继续前行。图 3-5 中图(c)与图(d)中 AGV 依次躲开第二、三个障碍物。经过三次小幅转向修正后, AGV 穿过狭窄区并重新对齐全局路径。





 图 3-5 本文算法在 20×20 环境下的运行过程


为了进一步验证融合算法在 AGV 运行过程中能够规划出全局最优路径，并保证及时规避随机动态和静态始障碍物，将与 ACO 和 HLOPSO 算法做了对比仿真，结果如图 3-6 所示。由图 3-6(a)可知，混合 ACO 直接穿过第一个障碍物，且与 (10,10) 红色障碍物有碰撞，并因其过于追求目标点而与 (16,16) 及 (17,17) 的红色障碍物发生碰撞。在图 3-6(b)仿真图中，混合算法在后期末追随全局路径的关键节点，导致与第一个和第三设置障碍物发生碰撞，从而影响了避障效果。图 3-6(c)为本章混合算法所得最终规划路径，成功躲避动态障碍物以及后期随机加入静态障碍物，在兼顾全局最优的同时，还能实现局部的避障。



(a)ACO 路径规划



(b)HLOPSO 路径规划



(c) EIHLO 路径规划

图 3-6 不同算法路径对比图

为了更加直观显示 AGV 运行过程中路径规划性能，仿真通过对 AGV 的线速度、角速度、位姿等参数进行实时采集，绘制出相关的性能曲线，从而直观地展示算法的控制效果。仿真结果清晰地反映 AGV 在动态障碍物规避、狭窄通道穿越等路径规划过程中的动态行为和控制效果。仿真结果表明，在复杂的环境下，AGV 依旧在线速度、角速度和姿态角度等方面表现出良好的效果，可以实现高效率、高稳定性的路径规划。图中纵坐标分别表示线速度角、速度姿态角度，横坐标表示时间步长。如图 3-7 所示。




图 3-7 混合算法路径及性能对比图

从图 3-7 可以看出本文算法在路径规划时遇到新增的障碍物 (6,7)，所以 AGV 线速度和角速度明显下降，图 3-7 可以看出 AGV 为了躲避障碍物而远离目标点，使得姿态角度临时增大。另外两种算法并未进行规避，因此速度、姿态角度未发生明显改变；而运行到栅格 (9,10) 时，AGV 为了躲避障碍物的速度再次明显下降，躲避过程类似；运行至区域 (11,12) 时，ACO 和 HLOPSO 算法虽然避开了障碍物但是并未靠近全局规划路径，而本文改进融合算法始终以全局路径关键节点为目标点，近距离靠近全局路径的又完成避障，故 AGV 的速度缓慢；如图 3-7 所示 AGV 运行至 (13,14) 附近时，因为要躲避多处障碍物故速度最慢，AGV 的角速度以近乎自转的方式大幅度调整。在躲避 (13,14) 后并未像另外两种算法过于追求目标节点而与障碍物发生碰撞，选择与障碍物保持安全距离然后并不断加速。三种路径规划算法性能指标对比如表 3-3。

表 3-3 几种路径规划算法性能指标对比

混合算法	全局路径/m	障碍接触次数	关键节点	运行时间/s	最终路径/m
ACO	25.213	5	5	29.400	25.455
HLOPSO	28.627	5	7	27.100	25.467
EIHLO	24.319	1	3	25.160	26.434

从表 3-3 可知，本文改进的 EIHLO 算法全局路径规划 24.319 米，比 ACO 路径减少 4%，比 HLOPSO 算法路径规划长度减少 15%。ACO 全局路径规划关键节点也少于另外两种算法，混合 ACO 最终路径规划长度为 25.455 米，混合 HLOPSO 算法路径规划长度为最终 25.467 米，本文改进的 EIHLO 和 DWA 融合算法最终路径长度为 26.400 米，虽然本文改进融合算法在路径上比其他两种融合算法长，但是动态避障最重要的是保证行驶安全不与障碍物发生碰撞，另外两种算法过于追求目标，而导致与障碍物发生碰撞。其他两种算法与障碍物接触的次数是本文算法的 5 倍。并在运行时间上比 HLOPSO 融合算法少 7.16%，比 ACO 融合算法少 14.4%，做到了即安全又快速。由此可以证明本文改进 EIHLO 与 DWA 算法具有可行性和的优越性。

为进一步证明改进融合算法的有效性，分别在 T 型环境和 40×40 地图中运行，从图 3-8(a)中可以看出，混合算法成功避免所有 T 型陷阱并且灵活躲避所有新增动态、静态障碍物。图 3-8(b)复杂环境下同样成功绕开障碍快速寻找到最优路径。




图 3-8 本文算法在不同环境下运行图

3.3 本章小结

本章研究了基于 EIHLO 与 DWA 的混合算法。首先，针对传统 DWA 全局性差、避障性能较低等问题，对传统 DWA 算法进行改进，添加角评价函数，提高 DWA 算法的避障性能及运行稳定性，引入自适应动态改变权重系数。对改进的 DWA 算法进行仿真，证明改进算法的可行性。其次，通过 EIHLO 进行全局路径规划，提取全局路径规划的关键节点，引入改进 DWA 进行局部路径规划，规避随机加入的未知静态障碍物与动态障碍物。最后，将改进的算法与其他算法进行比较，通过仿真验证了改进算法的有效性和可靠性。在简单的 T 型陷阱环境和复杂的 40×40 环境下进一步仿真，验证了算法的有效性和可行性。

第4章 基于 EIHLO 的多 AGV 路径规划

4.1 冲突类型及解决策略

单个 AGV 可以根据 EIHLO 规划出合理的路线。但是实际生活中，往往需要多台 AGV 协调运作，提高运行效率。当各个 AGV 起始点和目标点不同，多辆 AGV 行驶路径往往会出现重叠情况，使得 AGV 在执行任务时会出现碰撞问题。所以必须解决多 AGV 的路径冲突问题。

4.1.1 冲突类型

在路径规划中，多个 AGV 在同一环境中进行运行时，可能会争夺路径资源发生冲突，影响系统效率和存在安全隐患。常见的冲突类型包括迎面行驶的向相遇冲突、关键路径节点竞争的节点冲突、因速度差异导致赶超冲突等情况^[56]。冲突类型如图 4-1 所示。




图 4-1 三种冲突类型图

1) 相遇冲突

在多 AGV 环境中，两辆 AGV 沿着同一直线相向行驶，它们的运动方向相反且路径重叠，随着时间推移，两者之间的距离会逐渐缩短。如果不加干扰，将在一段时间后发生碰撞，对多 AGV 系统的运行效率和安全性能造成严重的影响。如图 4-1 所示中的 AGV1 与 AGV2，此时两辆 AGV 之间的冲突即为相遇冲突。

2) 追赶冲突

在多 AGV 工作环境中, 如果两辆 AGV 之间存在速度差异且在同一条直线路径上同向行驶, 后面的速度大于前面速度, 如图 4-1 所示中的 AGV2 与 AGV3, 若不对其进行干预, 等待一段时间后, 两辆 AGV 会产生相撞。在这种情况下, 两辆 AGV 之间的冲突即为追赶冲突。

3) 节点冲突

在多 AGV 工作环境中, AGV 之间的节点冲突发生拓扑网络的关键交汇区, 方向存在一定夹角。此时两辆 AGV 沿着不同的方向前进, 若未对两辆 AGV 实施协同调度策略, 随着时间的推移, 两辆 AGV 会在同步到达特定节点, 如图 4-1 所示中的 AGV1 与 AGV4 导致 AGV 之间发生安全风险, 此时两辆 AGV 之间的冲突即为节点冲突。

4.1.2 解决策略

在多 AGV 路径规划中, 要提高协同运作效率和解除上述的冲突, 需要对 AGV 优先级进行规定, 且认为环境中 AGV 结构相同、大小一致且电量充足。当预测到 AGV 之间可能发生冲突, 冲突的 AGV 之间的优先级大小进行评估, 优先级判定规则如下^[57]:

1) 评估 AGV 载货状态。负载 AGV 的优先级高于空载 AGV 的优先级;

2) 评估其任务的紧急程度。任务紧迫性越高, 执行任务的 AGV 优先级越高; 若均空载 AGV, 则依据 AGV 序号的大小设定优先级, AGV 序号越小, AGV 的优先级越高;

3) 评估 AGV 接受任务的时间。AGV 执行任务紧迫性相同, 先接受任务的 AGV 优先级较高;

4) AGV 的序号大小。如都是空载、任务紧迫性一致、接受任务的时间相同, 序号越小, 赋予的通行权限越高。

针对相遇冲突, 在检测到发生相遇冲突时, 两个 AGV 降低速度的同时按照相同的方向偏转, 如 AGV1 向其左边偏转错位, AGV2 也向其左边偏转错位。解决相向冲突, 同时偏离角度不会过大, 确保解决冲突后, 路径规划依旧以全局路径关键节点为目标点。


针对追赶冲突, 当后方 AGV 的速度大于前方的速度时, 可能发生安全隐患。对发生碰撞冲突的各个 AGV 的优先级^[58-59], 将它们进行分级。优先级最高的正

常通过，而优先级相对低的 AGV 根据自身的速度，缓慢减少，优先级最高的 AGV 通过冲突节点时，两车之间不会相撞，优先级低的 AGV 恢复原来的速度。


针对节点冲突，首先确认发生冲突的各 AGV 的优先级顺序，优先级高的 AGV 继续前进，低优先级的 AGV 减速，在原地等待优先级高的一方通过碰撞节点，或者重新规划路径到达目的地。

4.2 改进 DWA 与 RVO 混合算法


在单 AGV 路径规划中，DWA 算法可以进行很好局部路径规划^[60]。但在多 AGV 路径规划中，由于 DWA 算法缺乏全局视野，无法预测和避免其它 AGV，导致路径规划的不稳定性和非最优性，造成 AGV 之间发生冲突或无法找到最优路径。在图 4-2(a)中，在相遇冲突时，AGV1 与 AGV2 都在等待对方通过冲突节点，导致处于僵持状态。在图 4-2(b)中，AGV2 在检测到前面有车时选择等待，增加路径规划运行时间。在图 4-2(c)中，即使 AGV1 经过冲突节点，AGV2 仍然还在停止等待状态，直到 AGV1 远离，AGV2 才开始运行，降低运行效率。



(a)相遇冲突



(b)追赶冲突



(c)节点冲突

图 4-2 DWA 解决冲突情况图

为了解决这个问题，本章在基于 EIHLO 规划出各个 AGV 全局路径的基础上，将 RVO 算法与改进 DWA 进行混合用于多 AGV 局部路径规划。

4.2.1 互动速度障碍法

相互速度障碍法(Reciprocal Velocity Obstacle, RVO)^[61]是对速度障碍法(Velocity Obstacle, VO)的改进，VO 是一种常用的 AGV 路径规划算法，用于避免 AGV 与环境中的障碍物碰撞。将运动学避障问题转化为空间约束优化问题，即根据 AGV 与障碍物的实时运动参数，构造具有时间维度的速度障碍区域，AGV 速度矢量在速度障碍区之外才能安全行驶。在 VO 研究过程中把 AGV 简化为一个质点，目标 AGV 视为圆。首先在目标 AGV 周围创建动态安全边界，该边界由 AGV 轮廓尺寸、障碍物半径及动态缓冲间距共同决定，形成运动状态实时调整的防护区域，确保 AGV 与障碍物间保持距离。其次，构建锥型的满足安全约束的可行速度集合。对于每个障碍物，可以在预测路径上选择若干时间节点，通过求解 AGV 和障碍物在不同时间点的相对位置，建立了基于位置信息的碰撞锥体模型。若 AGV 速度向量能穿越该碰撞锥体，需要对速度调整才能避免发生碰撞。 V_A 表示 AGV 速度和 V_O 表示目标 AGV 速度，相对速度 V_x 可用公式表示为：

$$V_x = V_A - V_O \quad (4-1)$$

其中， V_x 看作 AGV 速度，目标 AGV 看作静态障碍物，相对速度将 AGV 动态避障转为静态问题。速度障碍区随着障碍物位置和运动信息更新，公式表示为：

$$S(X_A, V_x) = \{X_A + V_x t \mid t \geq 0\} \quad (4-2)$$

其中, X_A 为 AGV 的位置, t 表示时间, $S(X_A, V_x)$ 表示从位置 A 出发的一条射线, 实际上是一条从 AGV 位置 X_A 出发, 沿着 V_x 矢量方向的一条射线, 与 P_O 扩展圈重叠后的物体相交时, 就表明它会有撞击, 把所有可能碰撞到的相对速度都聚集在一起, 就形成了一个相对碰撞区域(Relative Collision Zone, RCZ), 如图 4-3 中浅蓝色区域, 公式表示为:

$$RCZ = \{V_x | S(X_A, V_x) \cap P_O \neq \emptyset\} \quad (4-3)$$

直接采用相对碰撞区域进行描述会增加计算量, 需要将相对碰撞区域转换成绝对碰撞区域(Absolute Collision Zone, ACZ), 即图 4-3 中浅绿色区域。通过对 AGV 相对碰撞的区域运动速度进行平移 V_O , 从而获得绝对碰撞区。AGV 运动过程中, 必须要避开的危险区就是域绝对碰撞区域, 绝对碰撞区域的可表示为:

$$ACZ = \{V_A | S(X_A, V_x) \cap P_O \oplus V_O \neq \emptyset\} \quad (4-4)$$

其中, $\oplus$ 为闵可夫斯基矢量和运算, X_O 为目标位置。VO 原理图如图 4-3 所示。




图 4-3 速度障碍法原理图

VO 的优点在于理论框架简洁直观, 计算复杂度较低, 通过几何空间映射有效规避了对障碍物运动学模型的强依赖, 因此在避障领域具有重要应用价值。然而, VO 实际应用中仍面临若干关键挑战, 当两 AGV 互相避碰时, 使用相同的算法各自调整方向, 但由于同时调整, 新的速度可能又进入对方的障碍区, 导致

循环调整，形成决策振荡现象^[62]，导致 AGV 产生一系列方向上的微小改变。这是因为两辆 AGV 都在对方的车速以外，重新选择了新的车速，如图 4-4 所示。




图 4-4 算法中存在的抖动现象

振荡现象的产生会效率降低、能量浪费、路径不平滑，甚至容易造成路径拥堵。互动速度障碍法则是用来解决此问题，防止出现速度反复变化的情况，使用了 RVO 算法之后的避障效果展示如图 4-5 所示。




图 4-5 使用 RVO 算法消除抖动

RVO 算法核心思想是建立对称式责任分担制，假设环境中的 AGV 均具备自主感知与决策能力，通过信息交互构建协同避障承担一定的避障任务。此时，采用双向速度协商策略，AGV 仅需承担一半的轨迹修量，有效避免传统方法中因单边避让引发的轨迹震荡现象，通过迭代计算当前速度矢量与可行速度域的加权平均值，确保运动参数的连续性，相较于传统速度障碍法的随机采样策略，该算法通过引入速度场梯度优化模型，在保证碰撞避免完备性的同时，提升了多单元系统的运动协调效率。即不会产生震荡现象，AGV 的运动轨迹也会更加平滑。

RVO 缩小了 VO 的障碍物区域, 该算法是非常实用的算法, 在 AGV 的避碰路径规划中得到了广泛的应用。RVO 的定义可表示为:

$$RVO(V_o, V_A) = \{V'_A \mid 2V'_A - V_A \in VO(V_o)\} \quad (4-5)$$

互动速度障碍法原理图如图 4-6 所示。




图 4-6 互动速度障碍法原理图

4.2.2 混合算法优化过程

在 RVO 算法中, AGV 运动受到相邻 AGV 运动状态的协同约束。该方法通过构建对称式运动协调策略, 使 AGV 自主调整运动方向以消除潜在轨迹风险。而 DWA 则关注 AGV 运动学约束, 在满足加速度边界与转向能力可行域内, 采用启发式搜索策略筛选最优速度组合。通过将这两种算法进行混合, 协同避障机制与局部运动优化相结合, 既保留了个体运动学约束的完整性, 又融入行为耦合特性, 提升运动协调效率与系统鲁棒性^[63]。

由 DWA 速度计算出下一时间 AGV 的速度信息离散化成矢量集合 B。通过 RVO 计算出可能导致动态碰撞的速度范围(Velocity Obstacle Exclusion, VOE)集合, 根据 VOE 将由于策略趋同导致运动轨迹反复交错的速度从 RVO 集合中剔除, 得到 AGV 安全速度集合(Safe Speed Collection, SSC)可表示为:

$$SSC = \{V | V \in B, V \notin RVO\} \quad (4-6)$$

混合算法的原理图如图 4-7 所示。




图 4-7 RVO-DWA 算法原理图

首先，使用 ELHLO 规划出全局路径，AGV 提取全局路径关键节点并依次设为局部路径规划目标节点。基于三种约束后的速度空间采样，解析并生成可达速度集。通过对可达速度集进行归一化处理，并结合预定义的评价函数（如路径长度、时间消耗等），系统能够从中选取最优的局部路径。接下来，判断当前环境中是否有其他 AGV 存在。如果存在其他 AGV，则进一步判断其速度是否位于 RVO 速度区域，剔除可达速度集中与 RVO 区域相交的部分，得到安全速度集；再次以安全速度建立候选轨迹集合，并再次通过综合评价体系，采样策略获取候选轨迹集，并利用最优评价函数筛选出最优速度。判断冲突类型，根据相应的策略解决冲突，更新 AGV 当前最新状态，输出最优路径，使系统能够在复杂的多 AGV 环境中实现高效、安全的路径规划。如果当前环境的速度在 RVO 速度之外，继续按照全局路径规划行驶。如果不存在其他 AGV，则继续按照全局路径规划行驶。流程图如图 4-8 所示。




图 4-8 多 AGV 路径规划算法流程图

4.3 混合算法的避碰仿真

本节主要针对多 AGV 存在的三种不同路径冲突,在 20×20 栅格环境中仿真,并通过仿真验证了算法的有效和可行。设定的障碍物半径为 0.6, 初始状态观测值为 0.8, 航向角权重系数、距离权重分别为 0.05 和 0.15, 最高速度为 2 米/s, 轮间距为 0.3, 时间步长为 0.1 秒。仿真选用三台 AGV, 分别命名为 AGV1、AGV2、AGV3, 仿真采用 MATLAB R2021a 软件, 仿真环境为 Windows11 64 位; 处理器 Intel(R) Core(TM) i7-12700; 内存 16 GB。

4.3.1 相遇冲突仿真及分析

AGV1 的起始点坐标设置为 $S1(8,16)$ ，目标点坐标为 $G1(8,8)$ ，AGV2 起始点坐标设置为 $S2(8,8)$ ，目标点坐标为 $G2(8,16)$ ，AGV3 的起始点坐标设置为 $S3(9,1)$ ，目标点为 $G3(19,10)$ 。相遇冲突路径规划仿真过程如图 4-9 所示。




图 4-9 解决相遇冲突过程


从图 4-9 中可以看出，各个 AGV 根据改进的人类学习优化算法规划出全局路径行驶，并按照全局路径规划的关键节点作为路径规划的子目标点。在行驶的过程中两辆 AGV 出现在各自的探测范围内，根据冲突类型判断将会在 $(8,12)$ 发生相遇冲突，根据相应的解决策略，此时两辆 AGV 速度降低同时角度发生偏转，

而不是只让其中一个避让，减少避障时间，提高避障效率。直到冲突解决后，两辆 AGV 恢复各自的速度正常运行。到达各自的目标点后，路径规划结束。AGV1 的行驶路径长度为 9.317 米，AGV1 运行时间为 17.90 秒。AGV2 的行驶路径长度为 9.258 米，AGV2 运行时间为 18.20 秒。AGV3 的行驶路径长度为 13.195 米，AGV3 开始运行到停止时间为 22.90 秒。最终完成各 AGV 路径规划。相遇冲突各 AGV 路径规划仿真结果如表 4-1 所示。


表 4-1 相遇冲突各 AGV 路径规划仿真结果

AGV 序号	AGV1	AGV2	AGV3
起始点	(8,8)	(8,16)	(9,1)
目标点	(8,16)	(8,8)	(19,10)
路径长度/m	9.317	9.258	13.195
运行时间/s	17.90	18.20	22.90


由图 4-10 线速度、角速度姿态角度变化曲线，可以看出各个 AGV 运动状态的变化。从图 4-10(a)可以看出，当在探测范围内两辆 AGV 即将发生相遇冲突时，此时 AGV1 和 AGV2 的速度均降低等待冲突解决后，AGV1 与 AGV2 速度逐渐恢复直至达到最大速度，行驶至目标点附近再次降速。由图 4-10(b)可以看出，即将发生碰撞时，此时 AGV1 与 AGV2 的角速度减小开始避让，而 AGV1 与 AGV2 同时偏离当前路径，解除相向相遇冲突后，此时 AGV2 开始恢复到原有的运动状态开始继续运行，直到所有 AGV 到达各自的目标点，完成路径规划。



(a)线速度曲线



(b)角速度曲线



(c)姿态角度曲线

图 4-10 相遇冲突各 AGV 仿真结果性能对比图

4.3.2 追赶冲突仿真及分析

AGV1 的起始点坐标设置为 $S1(8,8)$ ，目标点坐标设置为 $G1(8,18)$ ，AGV2 起始点坐标设置为 $S2(8,10)$ ，目标点坐标设置为 $G2(8,16)$ ，AGV3 的起始点坐标设置为 $S3(9,1)$ ，目标点坐标设置为 $G3(19,10)$ ，此时的 AGV 优先级大小为： $AGV1 > AGV2 > AGV3$ ，追赶冲突路径规划仿真过程如图 4-11 所示。




图 4-11 解决追赶冲突过程


从图 4-11 中可以看出,各个 AGV 按照全局路径规划从各自的起始点向终点行驶。在行驶的过程中 AGV1 与 AGV2 行驶同时在同一条直线上且运行方向相同,根据冲突类型判断将会在 (8,15) 发生追赶冲突,根据相应的解决策略,AGV1 优先于 AGV2 行驶。此时 AGV1 且速度不变,但角度发生偏转,AGV2 速度降低,但是方向不发生偏转。等待冲突解决后,AGV1 返回全局路线继续行驶,AGV2 正常行驶,直到路径规划结束。整个过程中,AGV1 实际行驶路径长度为 10.701 米,AGV1 运行时间为 17.30 秒。AGV2 实际行驶路径长度为 5.700 米,

运行时间为 13.00 秒。AGV3 实际行驶路径长度为 13.185 米，运行时间为 24.00 秒。追赶冲突中各 AGV 路径规划仿真结果如表 4-2 所示。


表 4-2 追赶冲突各 AGV 路径规划仿真结果

AGV 序号	AGV1	AGV2	AGV3
起始点	(8,8)	(8,10)	(9,1)
目标点	(8,18)	(8,16)	(19,10)
路径长度/m	10.701	5.700	13.185
运行时间/s	17.300	13.000	24.000


由图 4-12 可以看出各个 AGV 运动状态变化。图 4-12(a)中,当检测到两辆 AGV 即将发生追赶冲突时, AGV1 的线速度不变,继续以当前速度行驶,在 AGV2 目标点附近速度有所降低,随后,加速行驶,在目标点附近降低速度确保平稳停止。在冲突检测阶段, AGV2 的速度降低,避免与 AGV1 发生碰撞。冲突解决后,由于接近目标点,速度逐渐减小。由图 4-12(b)可以看出,即将发生碰撞时,此时 AGV1 的角速度减小开始避让,调整运动方向, AGV1 成功避开了与 AGV2 的碰撞。冲突解决后回到全局路径恢复角速度,继续沿原定路径行驶。而 AGV2 角速度几乎不发生变化,保持原有角速度继续运行,直到 AGV2 到目标点。从图 4-12(c)中可以看出 AGV1 在发生碰撞附近姿态角度增大,而 AGV2 的姿态角度在冲突期间保持相对稳定,保持原方向行驶。在 AGV 运行过程按照规定优先级以及冲突解决策略,保证优先级高的 AGV 优先完成路径。



(a)线速度曲线



(b)角速度曲线



(c)姿态角度曲线

图 4-12 追赶冲突各 AGV 仿真结果性能对比图

4.3.3 节点冲突仿真及分析

在多 AGV 系统的路径规划仿真实验中，为每辆 AGV 设定明确的起始点和目标点，AGV1 的起始点坐标设为 $S1(2,6)$ ，目标点坐标设为 $G1(11,9)$ ，AGV2 起始点坐标设置为 $S2(8,16)$ ，目标点坐标设置为 $G2(8,9)$ ，AGV3 的起始点坐标设置为 $S3(5,13)$ ，目标点坐标设置为 $G3(14,13)$ ，AGV 优先级大小为： $AGV1 > AGV2 > AGV3$ ，节点冲突路径规划仿真过程如图 4-13 所示。




图 4-13 解决节点冲突过程


从图 4-13 中可以看出，各个 AGV 按照全局路径规划行驶。在行驶的过程中 AGV1 与 AGV3 行驶方向不同且方向存在一定的夹角。预测会在 (8,13) 附近发生碰撞。根据冲突类型判断为节点冲突，根据相应的解决策略，AGV2 优先于 AGV3 行驶。此时 AGV3 原地等待且速度降低，而 AGV2 继续遵循预设进行运行，在 AGV2 依照既定运动策略通过关键交汇区域后，此时 AGV3 重新激活原始状态其初始路径规划方案。在 AGV2 向目标行驶的过程中，预测会与 AGV1 在 (8,10) 发生节点冲突。AGV1 优先于 AGV2 行驶，AGV2 降速行驶且将行驶方向发生偏转，AGV1 行驶方向偏转且速度降低但是仍然高于 AGV2。等待冲突解决后，AGV1 与 AGV2 按照预设运动规划方案继续行驶，直到各自到达各自的指定位置后，路径规划任务结束。

在节点冲突运行过程中，AGV1 行驶路径长度为 10.592 米，AGV1 运行到停止时间为 15.60 秒。AGV2 的行驶路径长度为 9.061 米，AGV2 开始运行到停止时间为 15.70 秒。AGV3 的行驶路径长度为 8.745 米，AGV3 开始运行到停止时间为 17.80 秒。节点冲突各 AGV 仿真结果如表 4-3 所示。


表 4-3 节点冲突各 AGV 路径规划仿真结果

AGV 序号	AGV1	AGV2	AGV3
起始点	(8,8)	(8,10)	(9,1)
目标点	(8,18)	(8,16)	(19,10)
路径长度/m	10.592	9.061	8.745
运行时间/s	15.600	15.700	17.800


由图 4-14 线速度、角速度姿态角度变化曲线，可以看出各个 AGV 运动状态的变化。当 AGV2 与 AGV3 发生第一次节点冲突时，根据优先级策略，AGV2 的优先级高于 AGV3，此时 AGV2 保持原有状态运行，所以 AGV2 速度、角速度姿态角度基本保持不变，AGV3 原地等待，此时速度降低为几乎 0，姿态角度几乎不发生偏转，角速度减少。等待第一次冲突解决后，AGV3 恢复原行驶状态直至达到目标点。当 AGV1 与 AGV2 发生第二次节点冲突时，AGV1 与 AGV2 的速度均降低，但 AGV1 速度仍然高于 AGV2，AGV1 与 AGV2 姿态角度变化趋势相同。冲突解决后回到各自全局路径，恢复行驶状态，行驶至各自的目标点。从 4-14 看出 AGV1 发生碰撞姿态角度增大，而 AGV2 保持原方向行驶。节点冲突各 AGV 仿真结果性能对比如图 4-14 所示。



(a)线速度曲线



(b)角速度曲线



(c)姿态角度曲线

图 4-14 节点冲突各 AGV 仿真结果性能对比图

4.3.4 其他情况仿真及分析

为进一步证明算法的可行性，另外增加如图 4-15 两种情况，图 4-15(a)中完成了两种冲突避障。第一次冲突是 AGV2 和 AGV3 在 (8,13) 附近发生节点冲突。成功避障后，AGV2 继续行驶，将在 (8,12) 附近和 AGV3 再次发生相遇冲突。从图中看出成功解决两种冲突，并且三台 AGV 都按照 EIHLO 规划的全局路径回到各自的目标点。图 4-15(b)仿真模拟无冲突理想情况下三辆 AGV 的路径，展示

了算法在理想环境下的高效性和稳定性, 各 AGV 分别各自的起始点出发, 按照各自的路径行驶, 安全到达目标点, 完成各 AGV 路径规划。




图 4-15 其他情况仿真图

4.4 本章小结

本章讨论了 RVO 与改进 DWA 混合算法。首先, 介绍了路径规划中可能出现的不同冲突及其解决策略。其次, 由于多 AGV 路径规划中 DWA 算法缺乏全局视野, 可能无法预测和避免其它 AGV。综合考虑了 RVO 算法的特点, 将 RVO 算法与 DWA 算法进行混合, 解决多 AGV 不同冲突法的避障问题。最后, 设计了相应的环境场景来验证多 AGV 同时进行路径规划的可行性, 结果显示各个 AGV 均能安全抵达各自所设定的终点。又设计同时存在两种冲突的多 AGV 路径规划和无冲突的多 AGV 路径规划, 设计仿真结果表明, 该方法简单可行并适用于实际。

第5章 总结和展望

5.1 总结

由于社会和经济的迅速发展和政府大力扶持人工智能,如今生活中存在着许多 AGV 的身影,而 AGV 的路径规划是应用方面的关键问题。路径规划结果优劣是衡量 AGV 智能程度的重要指标,所以成为研究热点。本文围绕 AGV 路径规划问题展开研究,完成的研究工作和取得的研究成果如下:

本文针对 HLO 存在的弊端进行改进,并以 EIHLO 作为单个 AGV 全局路径规划算法;利用 EIHLO 和改进 DWA 进行单个 AGV 动态避障;最后,利用 EIHLO 作为全局路径规划算法,将 RVO 与 DWA 结合进行多 AGV 路径规划。具体工作如下:

1) 研究了一种 EIHLO 算法。首先,改进概率数、IKD 和 SKD 更新操作、改惯性权重系数。其次,给出详细收敛性证明,并用测试集验证研究算法收敛精度及迭代速度。最后,在不同的仿真环境中与其他算法进行路径规划对比,证明了 EIHLO 具有一定的优越性与可靠性。

2) 探讨了 EIHLO 算法与 DWA 的混合算法。首先,针对传统 DWA 存在全局性差、避障性能较低等问题,对传统 DWA 进行改进,并将改进 DWA 与传统 DWA 进行仿真对比,证明改进算法的可行性。其次,通过 EIHLO 进行全局路径规划,引入改进 DWA 进行局部路径规划,将全局路径规划的关键节点作为局部规划的子目标,规避随机加入的未知障碍。最后,利用仿真将改进的算法与其他算法进行对比,验证改进算法的有效。

3) 探讨了 RVO 与改进 DWA 混合算法。首先,对多 AGV 路径规划中可能出现的不同冲突提出不同解决策略。其次,使用 EIHLO 为每台 AGV 规划出从起点到目标点的全局路径,提取全局路径中的关键节点,作为局部路径规划的目标点。将 RVO 与改进 DWA 进行混合进行局部规划,解决多 AGV 冲突避障问题。最后,设计了不同的环境场景来验证改进的融合算法在多 AGV 路径规划的可行性,仿真结果表明各个 AGV 均能安全抵达各的终点。

5.2 展望

本文研究内容集中于 EIHLO 和 AGV 路径规划的相关问题，展开了一定的分析和研究，但由于时间、仿真设备以及自身学术水平等因素限制，本文仍存在很多地方需要进一步进行讨论研究：

1) 本文对路径规划问题的理论研究和仿真主要集中在二维平面上，三维空间可以更好模拟真实环境。所以接下来会在未来的路径规划研究中，对三维仿真环境进行研究，提高环境建模的复杂度。

2) 当前 AGV 运动速率较低，如何在保证 AGV 运动速度的前提下，高效地完成指派任务，提升 AGV 的作业效率，是亟待解决的问题。

3) 本文的仿真都是在 MATLAB 平台上进行的，可能与实际应用的输出结果存在偏差。因此后续研究需要在实际环境中对 AGV 进行具体的算法验证实验。

4) 在空间环境给定的条件下，如何保证大量 AGV 能够在相同的空间环境中，有效地协同作业，是未来 AGV 研究的关键问题。

参考文献

- [1] 蔡自兴,谢斌.机器人学[M].北京:清华大学出版社,2015:1-14,340-350.
- [2] 李研.落实“十四五”规划加快推进我国未来产业发展[J].科技中国,2021,(12):1-5.
- [3] 赵铁军,罗羽泉. 基于改进自适应遗传算法的点焊机器人 TSP 路径规划[J]. 机械工程师, 2019(10):7-9.
- [4] 袁斌,王伟博, 王辉. 基于改进的粒子群算法的多目标点路径规划[J].浙江科技学院学报, 2022,34(03): 225-232.
- [5] 刘春,彭太平. 大规模 AGV 的改进时间窗路径规划研究[J].计算机应用研究, 2023,40(01): 1-6.
- [6] 高宇,赵嵩郢. 基于动态窗口法的无人艇局部路径规划[J].船电技术, 2022,42(07): 50-54.
- [7] 张志文.AGV 路径规划与避障算法的研究[D].电子科技大学, 2018.
- [8] 柯星. 动态环境下多移动机器人路径规划研究[D].电子科技大学,2013.
- [9] Elsi M, Altius M, Su S F, et al. Robust Kalman filter for position estimation of automated guided vehicles under cyberattacks[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [10] 周宇.基于校园无人配送 AGV 的路径规划算法研究[D].浙江科技学院,2023.
- [11] 冯德胜.基于 ROS 的移动机器人导航系统研究[D].齐鲁工业大学,2021.
- [12] 姚陈鹏,石文博,刘成菊,等. 移动机器人导航技术综述[J].中国科学:信息科学,2023, 53(12):303-2324.
- [13] 王春颖,刘平,秦洪政.移动机器人的智能路径规划算法综述[J].传感器与微系统,2018,37(8):5-8.
- [14] 梁凯,毛剑琳.基于改进蚁群算法的室内移动机器人路径规划[J].电子测量技术,2019,42(11): 65-69.
- [15] Luo Q, Wang H, Zheng Y, et al. Research on path planning of mobile robots based on improved ant colony algorithm[J]. Neural Computing and Applications, 2020, 32 (6): 1555-1566.
- [16] Phung M D, Ha Q P. Safety-enhanced UAV path planning with spherical vector-based particle swarm optimization [J]. Applied Soft Computing, 2021, 107: 107376.
- [17] Fernandes P B, OLIVEIRA R, NETO J F. Trajectory planning of autonomous mobile robots applying a particle swarm optimization algorithm with peaks of diversity [J]. Applied Soft Computing, 2022, 116: 108.
- [18] Jerald J, Asokan P, Saravanan R, et al. Simultaneous scheduling of parts and automated guided vehicles in an FMS environment using adaptive genetic algorithm[J]. The International Journal of Advanced Manufacturing Technology, 2006, 29: 584-589.
- [19] 佟云昊,席志红.基于蚁群算法的智能路径规划[J].电子科技,2025,38(01):23-28
- [20] 张浩,刘薇. 基于改进蚁群算法的机器人路径规划 [J]. 科学技术与工程,2025,25(03):1142-1149.
- [21] Yan X Z, Ding R C, Luo Q H, et al. A Dynamic Path Planning Algorithm Based on the Improved DWA Algorithm[C]//2022 Global Reliability and Prognostics and Health Management (PHM-Yantai).IEEE, 2022:1-7.
- [22] Tan Z K, Wei Naxin, Liu Zheng feng. Local Path Planning for Unmanned Surface Vehicle based on the Improved DWA Algorithm[C]. //2022 41st Chinese Control Conference (CCC). IEEE, 2022: 3820-3825.

- [23] Zhang Hong, Sun Chun-Long, Zheng Zi-Jun, et al. A modified dynamic window approach to obstacle avoidance combined with fuzzy logic[C]//2015 14th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES). IEEE, 2015: 523-526.
- [24] 胡庆朋,王涛,张如伟.改进蚁群算法在 AGV 全局路径规划中的研究[J].信息技术与信息化,2019(03):116-118.
- [25] 李开荣,刘爽,胡倩倩,等.基于转角约束的改进蚁群优化算法路径规划[J].计算机应用,2021,41(9):2560-2568.
- [26] 杨立伟,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.
- [27] 李涛,赵宏生.基于进化蚁群算法的移动机器人路径优化[J].控制与决策,2023,38(3):612-620.
- [28] Zhang, Z, Chen J, Zhao W B. Multi-AGV route planning in automated warehouse system based on shortest-time Q-learning algorithm[J].*Asian Journal of Control* 2024, 26.2: 683-702.
- [29] Liu J, Yang j, Liu h, et al. An improved ant colony algorithm for robot path planning [J]. *Soft Computing*,2017, 21(19): 5829 -5839.
- [30] Yu Z, SI Z, LI X, et al. A novel hybrid particle swarm optimization algorithm for path planning of UAVs [J]. *IEEE Internet of Things Journal*, 2022, 9(22): 22547-58.
- [31] Riahi V, Kazemi M. A new hybrid ant colony algorithm for scheduling of no-wait flow shop[J]. *Springer Nature*, 2018, 18(1): 55-74.
- [32] Che G, Liu L, Yu Z. An improved ant colony optimization algorithm based on particle swarm optimization algorithm for path planning of autonomous underwater vehicle[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2020, 11(8): 3349-3354.
- [33] 王松涛.基于优化的遗传算子改进蚁群算法 AGV 路径规划[J].自动化应用,2017(03):47-49.
- [34] 胡治锋,陈冬方,李庆奎等.基于模拟退火蚁群算法的拣货路径规划[J].电子设计工程,2021,29(24):80-83.
- [35] 徐洁,张锐,汪志锋.改进蚁群算法在自动导引车路径规划中的应用[J].工业仪表与自动化装置,2023.291(03):88-92.
- [36] 杜云,刘冰,邵士凯,等基于改进粒子群算法的无人机航迹规划[J].河北工业科技,2019,36(5):335-340.
- [37] 王翼虎,王思明.基于改进粒子群算法的无人机路径规划[J].计算机工程与科学,2020,42(9):1690-1696.
- [38] 付兴武,胡洋.基于改进粒子群算法的三维路径规划[J].电光与控制,2021,28(3):86-89.
- [39] 程泽,王尔刚,孙颖,等.基于免疫克隆粒子群算法的无人机航迹规划[J].弹箭与制导学报,2014,34(3):179-182.
- [40] 王利民,孙瑞峰,翟国栋,等.融合改进 A*算法与动态窗口法的煤矿足式机器人路径规划[J].工矿自动化,2024,50(06):112-119.
- [41] 李永真,黄学功,张志安.基于融合蚁群-A*算法的多目标路径规划方法[J].计算技术与自动化,2024,43(04):66-72.
- [42] Liu Y H, Wang T, Xu H Z. PE-A* algorithm for ship route planning based on field theory.[J]*IEEE Access* 2022,(10): 36490-36504.
- [43] 杨锋英,刘会超.AGV 作业调度模型及改进的 DE 算法研究[J].计算机工程与应

- 用.2014.50(09):225-230.
- [44] 刘彪.移动机器人路径规划算法的研究与仿真[D].内蒙古大学, 2022.
- [45] 王永胜,罗禹贡,黄晨,陈锐,江发潮.基于拓扑地图的自主泊车路径协调与优化策略[J].中国公路学报,2021,34(01):177-187.
- [46] 郭辛,吴佳彬,李林等.一种基于维诺图的星图识别算法[J].激光与光电子学进展,2025:1-15.
- [47] Wang L, Ni H, Yang R. An Adaptive Simplified Human Learning Optimization Algorithm[J].Information Sciences,2015(320):126-139.
- [48] Wang L, Pei J, Wen Y, et al. An improved adaptive human learning algorithm for engineering optimization [J]. Applied Soft Computing, 2018, 71: 894-904.
- [49] 郑新宇,李媛,刘晓琳.改进北方苍鹰优化算法的收敛性及其性能对比分析[J].计算机科学与探索,2024,18(12):3203-3218.
- [50] 潘峰,周倩,李位星.标准粒子群优化算法的马尔科夫链分析[J].自动化学报, 2013,39(04):381-389.
- [51] 张平改.引入推理机制的人类学习优化算法研究及其应用[D].上海大学,2021.
- [52] You X, Liu S, Shuai D. On parallel immune quantum evolutionary algorithm based on learning mechanism and its convergence[C]// International Conference on Natural Computation, Xi'an, China, 2006: 903-912.
- [53] Ding H, Gu X. Hybrid of human learning optimization algorithm and particle swarm optimization algorithm with scheduling strategies for the flexible job-shop scheduling problem[J]. Neurocomputing, 2020, 414: 313-332.
- [54] 李志鹏,李明.融合改进蚁群算法和动态窗口法的 AGV 路径规划[J].物流技术,2024,43(07):73-83.
- [55] 杨振,李俊丽,杨立炜,等.安全性 A*融合 DWA 的分布式多移动机器人路径规划方法[J].控制工程,2024,31(12):2284-2295.
- [56] 吉红,赵忠义,王颖丽,等.复杂环境下多 AGV 路径规划与调度系统研究[J].机械设计,2023,40(06):110-115.
- [57] 曾钰桔.基于融合算法的 AGV 路径规划及避障研究[D].昆明理工大学,2023.
- [58] 于琪,张静.基于融合任务规则优先级蚁群算法的多 AGV 路径规划实现研究[J].机电工程技术,2024,53(03):190-194.
- [59] 李腾,丁佩佩,张茹兰.基于动态避障优先级与预测的多 AGV 无冲突路径规划[J].系统工程,2024,42(03):50-62.
- [60] 温颖,王冬梅,路玉麟.基于改进 A*和改进 DWA 相融合的 AGV 路径规划[J].农业装备与车辆工程,2024,62(09):123-127.
- [61] Claes D, Tuyls K. Multi robot collision avoidance in a shared workspace[J]. Autonomous Robots, 2018,42(8): 1749-1770.
- [62] 康雪晶.复杂环境下移动机器人避障控制算法的研究[D].天津工业大学,2020.
- [63] 吴学礼,史思远,宋凯等.基于改进 VO 算法与动态窗口法的自主避障[J].科学技术与工程,2024,24(14):5928-5934.

攻读学位期间发表的学术论文

- [1] 王勤, 魏利胜. 基于改进 HLO 和动态窗口的 AGV 动态避障路径规划算法[J]. 电子测量与仪器学报, 2025, 39 (02): 213-221. (EI, 待检索)
- [2] **Qin Wang**, Xinjie Tao, Shaoyu Tang. A Novel Human Learning Optimization Algorithm Incorporating PSO[C]//The 39th Youth Academic Annual Conference of Chinese Association of Automation (YAC2024), DaLian, China, 7-9 June, 2024: 2024:1314-1317. (EI: 20243316866480)
- [3] **Qin Wang**, Shaoyu Tang. An Adaptive Improved Human Optimization Algorithm for Global Path Planning in AGV[C]//2024 5th International Conference on Computer Engineering and Application (ICCEA2024), Hangzhou, China, 12-14 April, 2024: 56-62. (EI: 20243316886103)
- [4] Xinjie Tao, Lisheng Wei, **Qin Wang**. Alzheimer's Disease Imaging Recognition Based on Improved 3D-ShufflenetV2 Network[C] //International Conference on Life System Modeling and Simulation. Singapore: Springer Nature Singapore, 2024: 276-289. (EI: 20250917965963)

攻读学位期间获得的奖励

- [1] 获得 2025 年安徽工程大学**优秀毕业生**
- [2] 获得 2022-2023 学年安徽工程大学研究生**二等奖学金**
- [3] 获得 2023-2024 学年安徽工程大学研究生**一等奖学金**
- [4] 获得 2024-2025 学年安徽工程大学研究生**一等奖学金**
- [5] 获得 2023 年中国传感器创新创业大赛**华东区一等奖**
- [6] 获得 2023 年中国传感器创新创业大赛**决赛三等奖**

致 谢

硕士生涯不知不觉已经走到尾声，之前总觉来日方长，没想到毕业却也悄然来临。这三年来，有太多的记忆。回首往事，都是记忆，既是结局，又是起点。

教诲如春风，师恩似深海。真诚感谢魏利胜老师三年来对我的关心和教导，从最初的讨论选题、小论文的校订及毕业论文的撰写，他的学术态度，扎实的理论知识，以及他的耐心教导，都让我感到敬佩。衷心感谢张平改老师耐心地教导，总能在迷茫的时候用简单的话语道出深刻的道理。

时光清浅，不负相遇。很幸运读研期间能够遇到实验室的伙伴以及室友，三年时光转瞬即逝，大家在一起快乐时光却还历历在目。很荣幸能和大家一起经历宝贵的一段人生旅程，感谢大家给予的帮助与支持，祝愿所有人前程似锦。

读研不易，父母的支持与鼓励一直是我最大的动力，每当迷茫困惑时，家人给予及时鼓励。感谢他们在我求学生涯中默默站在背后，做我坚强的后盾。唯一能报答他们的就是更加努力地学习和工作，用行动来回报他们的恩情。

最后，向参加论文评阅、答辩及提出宝贵意见的专家、老师致以衷心的感谢！

王勤

安徽工程大学电气工程学院

二〇二五年五月

尚德敏学 唯实惟新

