

中国科学技术大学

专业硕士学位论文



人与搜救无人机的信任建模和协同 控制方法研究

作者姓名： 夏睿钰

学科专业： 电子信息

完成时间： 二〇二五年六月二十三日

University of Science and Technology of China

A dissertation for master's degree



Research on Trust Modeling and Cooperative Control Methods Between Humans and Search-and-Rescue Drones

Author: Xia Ruiyu

Speciality: Electronic and Information Engineering

Completion date: June 23, 2025

中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文，是本人在导师指导下进行研究工作所取得的成果。除已特别加以标注和致谢的地方外，论文中不包含任何他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了明确的说明。

作者签名：_____

签字日期：_____

中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一，学位论文著作权拥有者授权中国科学技术大学拥有学位论文的部分使用权，即：学校有权按有关规定向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅，可以将学位论文编入《中国学位论文全文数据库》等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、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一致。

控阅的学位论文在解密后也遵守此规定。

☒ 公开 ☐ 控阅（____年）

作者签名：_____

导师签名：_____

签字日期：_____

签字日期：_____

摘要

搜救无人机机动性强、覆盖广，可在地震、矿难等灾害中快速执行搜索与投递任务；人则具备高级决策与环境感知优势。要在复杂灾情下充分发挥人机协同优势，需构建动态且可解释的信任机制。然而现有研究在搜救无人机的人机信任建模方面尚不完善，难以将信任有效融入协同控制优化中。

针对上述问题，论文以信任机制为基础，围绕信任建模、控制权限和任务分配优化三方面展开研究，提出了基于人机信任的协同控制方法，提升了人机系统在复杂环境中的协同决策质量和救援效率。主要工作包括：

（1）针对现有信任模型与搜救无人机协同场景的不适配问题，提出了基于搜救无人机能力的人机信任演化模型。该模型结合救援场景下无人机的多维能力表现与人类认知偏差因素，刻画信任的动态演化过程。通过分析各参数意义和相关性质，确保模型的可解释性。仿真实验结果表明，该信任模型能够有效跟踪信任值的实时变化，为后续基于信任的协同优化提供支撑。

（2）针对单机协同搜救任务中仲裁策略难以应对机器高置信度错误和人机认知偏差问题，设计了基于最小化信任偏差的动态透明度策略，通过信任模型预测选取最优透明度水平，使得信任处于合理范围。构建了基于信任的自适应仲裁策略，根据信任值动态调整控制权边界，并结合碰撞风险与信任水平优化权限平滑过渡，确保人能及时修正机器错误决策。仿真实验结果表明，该方法能够有效降低人对无人机能力的认知偏差和机器碰撞概率，提升系统的协同效能。

（3）针对多机协同救援任务中无人机能力波动对分配策略的影响，提出将人机信任作为无人机能力的动态评价指标，构建了兼顾任务成功概率与执行效率的优化目标函数，并设计了基于信任的锦标赛选择策略，提高求解效率，实现任务合理分配。仿真实验结果表明，该方法在任务分配效率和任务成功率方面均优于传统方法，能够有效提升多机协同作业的整体救援效能。

关键词：搜救无人机；人机协同；信任建模；任务分配

ABSTRACT

Search and rescue (SAR) drones feature high mobility and broad coverage, enabling rapid search and delivery in disasters such as earthquakes and mining accidents. Humans complement this with advanced decision-making and situational awareness. To fully exploit the strengths of human-drone collaboration in complex scenarios, a dynamic and interpretable trust mechanism is essential. However, current research on human-drone trust modeling in SAR is still limited, which hinders its effective integration into collaborative control.

This thesis addresses the challenge by proposing a trust-based collaborative control framework, focusing on trust modeling, authority arbitration, and task allocation. The approach improves joint decision-making and rescue efficiency in complex environments. The main contributions are as follows:

(1) To address the mismatch between existing trust models and SAR drone collaboration, a capability-based trust evolution model is proposed. It integrates multi-dimensional performance metrics and human cognitive bias to capture real-time trust dynamics. Parameter analysis ensures model interpretability by revealing component meanings. Experiments validate its accurate tracking of real-time trust dynamics, supporting trust-informed collaborative optimization.

(2) To address high-confidence errors and cognitive bias in single-drone SAR tasks, a dynamic transparency strategy is proposed to minimize trust deviation by selecting optimal transparency levels via the trust model. An adaptive arbitration strategy is developed to adjust control authority dynamically based on trust, ensuring smooth transitions by considering collision risk and trust levels. Experiments show the approach reduces cognitive bias and collision probability, improving collaboration performance.

(3) To address fluctuating drone capabilities in multi-drone task allocation, trust is used as a dynamic evaluation metric. An optimization objective function balances task success probability and execution efficiency, while a trust-based tournament selection strategy improves solution efficiency and ensures effective task allocation. Simulations show the method outperforms traditional approaches in allocation efficiency and task success rate, enhancing overall multi-drone rescue performance.

KEY WORDS: Search and Rescue Drones, Human-Machine Collaboration, Trust Modeling, Task Allocation

目录

第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 典型应用场景描述	3
1.2.1 单机共享控制场景	3
1.2.2 多机任务分配场景	4
1.3 国内外研究现状	4
1.3.1 单机共享控制场景	4
1.3.2 多机任务分配场景	5
1.3.3 人机信任相关研究现状	6
1.3.4 研究现状总结	8
1.4 论文工作内容和结构安排	8
1.4.1 工作内容	8
1.4.2 结构安排	9
第 2 章 相关基础知识	11
2.1 强化学习基础理论	11
2.2 人机混合控制方式	13
2.3 意图推理方法	14
2.4 遗传算法	15
第 3 章 基于搜救无人机能力的人机信任模型	18
3.1 引言	18
3.2 机器能力刻画	19
3.2.1 客观机器能力刻画	19
3.2.2 主观机器能力刻画	20
3.3 人机信任演化模型	23
3.3.1 信任演化模型	23
3.3.2 模型理论分析	24
3.3.3 模型参数估计	26
3.4 信任模型实验设计	28
3.4.1 场景描述与仿真设计	28
3.4.2 机器能力函数	30
3.4.3 仿真实验设置	31

3.5 实验结果分析	32
3.5.1 信任模型验证	32
3.5.2 信任与人类控制频次	34
3.5.3 信任影响机理与设计启示	35
3.6 本章小结	36
第 4 章 基于信任的自适应仲裁策略	37
4.1 引言	37
4.2 基于最小化信任偏差的动态透明度策略	37
4.2.1 信任认知路径与透明度作用	37
4.2.2 三级透明度界面设计	39
4.2.3 透明度对动态认知因子的影响实验	41
4.2.4 最小化信任偏差的透明度选取	44
4.3 基于信任的自适应仲裁策略	45
4.3.1 信任-能力耦合的机器控制权边界	46
4.3.2 基于冲突检测与信任水平的权限平滑过渡	46
4.4 基于信任的单机共享控制框架	48
4.5 实验与验证	49
4.5.1 仿真实验设置	49
4.5.2 实验结果与分析	50
4.6 本章小结	54
第 5 章 基于信任的多机任务分配方法	55
5.1 引言	55
5.2 场景描述与问题建模	55
5.2.1 无人机集合	56
5.2.2 任务集合	58
5.2.3 任务完成时间	59
5.3 基于信任和最短时间约束的目标函数设计	59
5.3.1 信任动态演化方程	59
5.3.2 优化模型建立	60
5.3.3 约束条件	61
5.4 基于信任的改进遗传算法设计	61
5.4.1 染色体编码	61
5.4.2 适应度函数	61
5.4.3 基于信任的锦标赛选择	62

5.4.4 交叉与变异	62
5.4.5 算法整体流程	63
5.5 实验与验证	64
5.5.1 仿真实验设置	64
5.5.2 实验一：TIGA 方法与基准遗传算法性能对比	66
5.5.3 实验二：基于信任的目标函数设计与传统设计的对比	70
5.6 本章小结	74
第 6 章 总结与展望	75
6.1 总结	75
6.2 展望	75
参考文献	77
致谢	84
在读期间取得的科研成果	85

插图清单

图 1.1	DARPA 机器人地下挑战赛	1
图 1.2	共享控制中的人机决策融合示意图	3
图 1.3	论文框架	9
图 2.1	强化学习结构示意图	11
图 2.2	遗传算法流程图	16
图 3.1	无人机控制仿真环境	28
图 3.2	不同操作者的信任量表值和 MCDTM 模型值	32
图 3.3	MCDTM 模型的信任量表值与模型值	33
图 3.4	人机信任与控制频次的关系	34
图 3.5	不同信任区间下各类任务结果占比分布	35
图 4.1	搜救无人机协同控制系统框图	38
图 4.2	透明度信息示意图	39
图 4.3	实验环境中的三种透明度界面示例	42
图 4.4	参与者在三种透明度下的信任动态变化曲线	44
图 4.5	不同透明度下的人机系统性能	45
图 4.6	基于信任的单机共享控制框架	48
图 4.7	交互场景示意图	49
图 4.8	单机控制：所提方法与基准方法性能对比	51
图 4.9	仲裁策略：存在碰撞风险时的飞行轨迹对比	52
图 4.10	仲裁策略：机器高置信度错误下的飞行轨迹对比	53
图 4.11	透明度选取：动态透明度曲线	53
图 4.12	动态透明度策略：单一与动态透明度下信任曲线对比	54
图 5.1	多无人机救援物资投递场景	56
图 5.2	PMX 示意流程图	63
图 5.3	救援场景 3D 地图	65
图 5.4	多机任务分配：无人机任务执行轨迹	68
图 5.5	收敛速度对比：TIGA VS BL	69
图 5.6	最优任务分配方案的总耗时对比：TIGA VS BL	69
图 5.7	最优任务分配方案的适应度值对比：TIGA VS BL	70

附表清单

表 2.1	介入控制和共享控制的特点对比	14
表 3.1	动作编号对应关系	29
表 3.2	四位操作者的信任模型参数值	32
表 4.1	不同透明度等级下的参数值和信任均值	43
表 4.2	单机共享控制实验参数设置	50
表 5.1	信任模型参数	65
表 5.2	无人机信息表	66
表 5.3	任务信息表	67
表 5.4	算法参数值	67
表 5.5	实验一：任务分配结果对比	68
表 5.6	无人机动态能力表	71
表 5.7	无人机基本信息表	72
表 5.8	第十轮任务信息表	72
表 5.9	实验二：任务分配结果对比	74

第1章 绪论

本章介绍了人与无人机开展协同搜救的产生背景和研究意义，对论文涉及的单机共享控制和多机任务分配场景进行了介绍，阐述了救援场景下人机协同控制方法和信任机制的国内外研究现状和不足，给出了全文的主要工作内容和结构安排。

1.1 研究背景及意义

随着信息技术的发展，智能无人系统正成为灾害应急管理的重要组成部分^[1-3]。无人机、无人艇、地面搜救机器人、水下搜救机器人等自主智能装备为应急搜救提供了全新的手段，并在大量实际救援行动中取得了很好的效果^[4-5]。我国《国家突发事件应急体系建设“十三五”规划》中提到要支持鼓励通用航空企业增加具有应急救援能力的无人机及相关专业设备，发挥其在抢险救灾、医疗救护等领域的作用^[6]。2022年国务院印发的《“十四五”国家应急体系规划》进一步明确，无人机等智能无人应急救援装备是安全应急产品和服务的发展重点^[7]。美国国防高级研究计划局（Defense Advanced Research Projects Agency, DARPA）也通过举办机器人地下挑战赛^[8]等活动推动搜救自主机器人的快速发展（如图1.1所示）。




图 1.1 DARPA 机器人地下挑战赛

作为新型救援力量，搜救无人机不仅具备快速响应和部署的优势，还能提供高空视角获取全面的灾情信息^[9]，在应急救援中展现出巨大的潜力。比如在地震救援中，人工智能（Artificial Intelligence, AI）赋能的无人机可自主扫描受灾区域，快速识别废墟下可能存在的生命迹象，大幅提高救援效率和准确性^[10]。而借助群体智能和分布式算法，多架无人机可以在无人干预的情况下自主分配救

援任务、规划飞行路径，并协同执行复杂的搜救任务^[11-12]。

然而灾后环境复杂多变，搜救无人机在飞行过程中难免遭遇强风^[13]、电磁干扰^[14]等不确定因素。这些突发干扰往往难以预判，一旦发生，极有可能导致无人机决策失误或飞行稳定性下降。此外，AI 算法决策过程的不可解释性和不确定性^[15-16]，使得 AI 驱动的搜救无人机在高安全性要求的救援场景中难以实现绝对可靠^[17]。

相比之下，人类在应对复杂且未知的环境时具备更高的认知判断能力和灵活应变能力，能在关键时刻弥补无人机的不足：面对电磁干扰、火灾烟雾、湍流风扰等高度非结构化因素时，人类可基于经验和直觉对环境中的威胁进行动态评估，并迅速拟定多种应对策略，提升系统决策的可靠性^[18]；当算法出现高置信度错误导致机器决策失误时，人类亦能及时介入并纠偏，避免因机器决策造成的救援失误^[19]。此外，人类拥有多源信息融合与高级推理能力，能够审慎评估无人机执行情况，为其路径规划^[20]和任务调度^[21]提供可行的决策参考。由此可见，在救援场景中采用人与搜救无人机协同的方式作业，不仅能充分发挥 AI 驱动的无人机在大范围巡查和实时数据采集与处理方面的技术优势，也能借助人类对动态环境的敏锐洞察与快速应变弥补算法不足，有望在信息获取、决策质量和任务效率上形成叠加效应^[22-23]。

充分发挥人机协同优势的关键在于构建有效的人机信任机制。人与机器的优势互补并非自然而然发生，而是取决于人能否准确认知无人机的真实能力。事实上，受制于机器算法的复杂性与不可解释性^[16]，人往往难以客观评估其实际能力。以目标搜寻任务为例，若人过度信任机器并将全部搜寻工作交由机器完成，则可能因为算法鲁棒性不足而遗漏重要目标；若人对机器缺乏信任而放弃利用其自主优势，则可能降低搜救效率。因此，构建能够让人机双方优势得到充分发挥的人机信任机制，对于提升搜救系统的整体性能至关重要。

此外，合理的人机信任机制在搜救场景中能显著提升系统的协同效率^[22]。当人对机器能力有充分认知时，信任水平能较好地反映无人机在当前救援任务下的能力边界，从而为人机协同系统的设计与调控提供重要依据。具体而言，人机信任可从两方面发挥作用：其一，在共享控制中依据实时信任动态调整人机决策权重——若信任值偏低，系统可适当提升人类操作者的控制优先级以保障安全；若信任值充足，则可进一步发挥无人机的自主决策优势，减少人类工作负载；其二，作为评估无人机综合表现的工具，在难以直接量化无人机综合性能或环境扰动导致机器能力波动的情形下，可利用人机信任来捕捉人类对机器的能力判断，并将之纳入到系统的优化流程和决策调整中。

因此，论文以人机信任为基础，围绕人机协同搜救任务中的两个关键场景展开研究，即局部层面的单机共享控制和全局层面的多机任务分配。具体而言，在

单机共享控制中，利用人机信任实时调节人类与单个无人机之间的控制权限；而在多机任务分配中，则将人机信任作为无人机能力的动态评价指标，以优化任务的分配策略。所提方法充分发挥了人与机器的协同优势，提升了人机搜救系统的整体效能，具有明确的研究价值与实践意义。

1.2 典型应用场景描述

1.2.1 单机共享控制场景

在灾后救援任务中，搜救无人机凭借其机动性和感知能力，能够在灾区快速展开搜索工作。例如，通过搭载红外摄像头、RGB 图像传感器等设备，无人机可以自主分析搜救区域内的目标并尝试确定被困人员的位置^[24]。然而，由于算法的不确定性、环境干扰和图像质量限制等因素，可能存在目标误报或遗漏的情况。因此通常需要人类操作员对无人机回传的现场画面和识别到的目标进行审查，判断是否存在误判或遗漏。一旦操作员发现疑似目标或搜救盲区，便可通过共享控制参与无人机控制回路，手动引导无人机前往新的搜救区域，执行进一步的探测、目标确认或物资投放等关键任务^[25]。

由于灾后环境往往复杂且不确定性强，交互界面中直接标注目标位置并不能充分考虑实时环境中风扰、电磁干扰等动态因素，可能导致无人机无法准确、及时地到达指定位置。此外，部分交互界面可能未配备直接标注目标位置的功能^[26]。因此，采用如图1.2所示共享控制方式，让操作员直接参与无人机的飞行控制，能够更灵活地应对现场环境变化，保证任务执行的安全性与有效性，且方法更具一般性。




图 1.2 共享控制中的人机决策融合示意图

在这种共享控制模式下，机器根据人类的控制输入推断其意图，并在此基础上提供相应辅助。例如，在引导过程中，系统可以结合操作员的指令优化飞行路

径,提高搜索效率,同时确保无人机能够自主避障并维持稳定飞行。当操作员确认无人机已成功识别目标后,即可退出控制回路,让无人机恢复自主运行,从而将注意力转向其他搜救任务以提升搜救效率。这种过程中人类介导机器目标识别与决策优化的交互模式被称为“人类引导的目标识别”。此类考虑人类意图的共享控制模式被广泛应用于人机协同作业中,如无人机目标引导^[27-28]、无人机竞速^[29]、无人机安全导航^[30]和机械臂协同装配^[31-33]等任务,具有较强的代表性和现实意义。同时,该场景能够清晰刻画人机信任在动态交互中的演化过程,随着任务推进,操作员会根据无人机的识别准确性动态调整信任水平,并相应调整自身在共享控制中的参与程度。

1.2.2 多机任务分配场景

在大规模灾后救援行动中,单台无人机往往难以高效完成大范围、多目标的搜救或物资投送任务,因此需采用多架无人机协同作业。实际任务中,无人机能力受环境干扰、通信链路波动及传感器故障等因素影响会发生动态变化,导致其在执行不同任务时的适应性存在差异。为提升救援效率和任务成功率,必须根据任务需求与无人机的实时能力状态动态调整任务分配^[34]。例如,周边环境复杂的任务宜由性能稳定、通信顺畅的无人机优先执行,而能力受限的无人机则应调整任务或重新规划路径,以降低因能力不足造成的任务失败风险。

然而,单纯依赖系统层面的静态或动态瞬时性能指标难以全面反映无人机在复杂环境下的综合表现,且搜救任务中对无人机的多维能力要求也导致直接量化无人机的综合性能变得困难。此时,人机信任作为人基于历史表现和交互经验对无人机能力形成的综合判断,能够在一定程度上补充对无人机能力的动态评估,并可作为多无人机系统中任务分配的重要辅助依据。通过引入信任机制,根据信任值动态调整任务匹配策略,不仅能提升任务适配性,还能增强系统整体的鲁棒性和响应能力。这种基于信任动态调整的任务分配模式适用于各种灾害区域大规模搜救、物资配送与应急评估任务,在现实应用中有广泛的适用性和重要的研究价值。

1.3 国内外研究现状

1.3.1 单机共享控制场景

应急救援(如城市救援、水下救援、矿区救援等)环境中的不确定性要求系统既具备人类操作员的高级决策能力,又能利用机器人技术提升任务效率与安全性。与传统的人类监控及干预模式相比,人机共享控制模式在应急响应速度、环境适应能力和减少操作延迟方面具有更显著的优势。

Allaban 等人开发了动态权重调整的混合共享控制架构,通过实时评估操作指令延迟和里程计漂移程度,自主调整人类输入与机器控制的融合比例,从而缩短任务完成时间且有着相比人类控制更低的碰撞风险^[35]。Zhou 等人则通过模糊控制策略综合考虑操作员的控制熟练度、疲劳度以及机器人自身的避障能力和控制可靠性信息,动态调整人机控制权限,从而有着相比纯人类控制或纯机器自主控制更平滑的运动和避障轨迹^[36]。Luo 等人在人工势场方法基础上,通过监测操作员交互过程中的肌电图信号识别人类意图,优化搜救无人机的自主控制策略和权限分配方式,从而提升了人机交互的流畅性与机器人的避障能力^[37]。

此外,现有研究逐渐关注到人机信任对共享控制效果的影响。Li 等人通过考虑人类认知负荷、控制平滑度和机器的安全性、顺从性等因素构建了双向信任模型,并基于信任值和其他安全约束动态调整人机的控制权限,从而提高了人类控制满意度并减少救援所需时间和碰撞概率^[38]。

综上所述,在应急搜救任务中采用人机共享控制模式能够降低机器在复杂环境中的碰撞风险、优化运动轨迹并减少人类工作量,提升协同救援系统的综合性能。而将人机信任纳入共享控制的权限分配设计中,能够进一步提高人类的满意度,降低其紧张情绪与认知负担^[38]。但当前共享控制领域对信任因素的研究还比较少,相关理论体系尚仍待完善。且现有权限分配方案难以处理机器高置信度错误对系统的影响,其动态调整机制仍需进一步改进。

1.3.2 多机任务分配场景

多机任务分配是无人机集群协同救援的关键环节,需在行动前基于灾情信息生成高效任务方案。指挥中心通过卫星、传感器等多源监测数据,获取受灾点位置和医疗物资等需求,利用智能算法为无人机规划救援路径。算法需统筹无人机续航、载重限制,以及气象、地形等环境约束,同时满足任务时效性与资源匹配度要求,在动态灾情中生成无冲突的最优解,以实现救援效率最大化。算法主要分为集中式求解算法和分布式求解算法两种^[39]。

集中式任务分配方法主要包括最优化方法和启发式方法。最优化方法如穷举法、图论方法、动态规划和分支定界法,能有效求解规模较小、问题定义清晰的任务分配问题,但随着任务规模与复杂性的增加,计算负担显著加重且难以处理动态环境中的随机性与不确定性^[40]。启发式方法则通过权衡运算时间和求解质量提供近似最优解,典型的代表包括遗传算法^[41-42]和粒子群优化算法^[43],这些算法因易于实现、计算复杂度低且性能优越而得到广泛应用。然而,大部分算法是针对特定的应用背景及约束条件进行改进,算法鲁棒性与可扩展性较低。^[39]

分布式任务分配方法又可进一步细分为自顶向下和自下而上的方法。自顶向下方法通过将复杂任务分解为多个子任务,再通过各无人机的协商与合作完成

任务分配，典型方法包括基于市场机制的算法^[44]、分布式马尔可夫决策方法和动态分布式约束优化方法。自下而上的方法则基于每个同构个体的行动决定总体趋势，对问题规模的变化不敏感，代表方法包括基于群智能的自组织算法^[45]、蚁群优化算法^[46]和阈值响应法^[47]。然而，随着异构无人机类型的增加和集群规模的扩大，上述算法的求解质量有明显下降。

尽管已有研究在任务分配方法上取得了较大进展，但在多机任务分配领域引入人类因素特别是人机信任的研究仍然较少。Hong 等^[48]提出 MAXQ 分层强化学习框架，通过任务分解与策略共享机制实现多机器人间的自主协调，有效扩展了操作员可控制的机器人规模，提升了任务完成效率。因此，未来研究中如何有效整合人机信任因素至多机任务分配决策，增强决策鲁棒性与实时性，将是一个重要的研究方向。

1.3.3 人机信任相关研究现状

人机信任的建模与量化是实现人机协同控制的关键问题。当前学术界尚未形成关于人机信任的统一定义，目前引用最多的信任定义是 Lee 和 See 提出的“在不确定和脆弱的情况下，代理人将帮助实现个人目标的态度”^[49]，其中的不确定性和风险指代理人有可能无法完成人类指定的任务。该定义将信任表述为一种心理学态度，导致难以进行准确量化。

随着人工智能（AI）技术的发展，自动化机器逐渐发展为具备高度自主决策能力的智能机器，人机也逐渐从“主-从”关系转变为合作关系，上述定义也不再完全适用于 AI 驱动的人机系统。在 AI 赋能的人机协同系统中，现有研究通常将人机信任与机器完成特定任务的能力或绩效关联起来^[38,50-52]。Hancock 等人^[53]通过元分析方法对现有文献展开分析，确定了三个主要的信任因素：与机器人相关的因素，即性能和属性；与人相关的因素，即能力和人类特征；与环境相关因素，即团队协作和任务特性。他们指出机器人性能因素与信任的关联最为显著。因此，近期研究逐步将人对机器的信任与机器性能表现、历史信任水平、经验等因素结合起来进行信任建模^[49,52,54-55]。但受限于信任量化可计算定义的缺失，部分模型采用“低、中、高”等离散方式刻画信任，难以应用在控制系统中。且模型大多基于人机信任在特定场景中的特征变量进行设计，难以迁移至其他场景使用。

根据建模技术的不同，现有信任模型可分为以下四类：

（1）以性能为中心的代数模型。此类方法借助代数公式，通过观测机器人性能评估信任值，计算简洁、实现成本低。例如，Floyd 等人提出了一种性能为中心的计算机信任模型，使用代数公式计算机器人表现与人机信任之间的关系，并应用于模拟地面无人驾驶机器人的协作任务中^[56]。Wang 等人考虑机械臂协同控

制中存在的机器安全约束、奇异性能、控制平滑和人类疲劳程度构建了代数模型，并将其应用到机械臂的协同控制任务中^[52]。

(2) 时间序列模型。此类模型通过历史数据捕捉信任随时间的变化趋势，适合于具有相对稳定的长时间信任演化过程，如 Lee 和 Moray 开发的自回归移动平均向量模型，用于描述人类对自动化系统的信任随时间演变的趋势^[57]。Hu 等人开发了考虑经验、累积信任和期望偏差的信任函数，并探讨了自动化机器误报和漏报对信任的影响^[54]。

(3) 马尔可夫决策过程/部分可观测马尔可夫决策过程模型。这些方法通过考虑信任状态的转移概率，系统地描述机器人状态与行为的转移过程。例如，Akash 等人通过部分可观测马尔可夫决策过程模型捕捉人类信任和工作负荷的动态变化，并用于机器人遥操作情境^[51]。

(4) 动态贝叶斯网络信任模型。该方法可利用事件之间的因果关系来预测信任值的演变，适合处理复杂的多阶段任务。例如，Xu 和 Dudek 提出的在线概率信任推理模型能预测人机交互中的信任变化^[58]。

这些模型从不同角度对人机信任进行了建模，为后续人机协同系统的优化与调控提供了理论基础。但也普遍存在可迁移性不足、与控制环节融合度不高等挑战，难以用于搜救无人机的协同控制优化中。

现有信任研究可分为两个主要方向：

(1) 利用决策解释性信息实现信任调控。主要通过提高机器透明度或优化界面设计等手段，调节人类对机器的信任水平，以引导合理的系统使用或监督。其中机器透明度代表“界面的描述性质量，即界面在帮助操作员理解智能代理的意图、表现、未来计划和推理过程等方面的能力”^[59]。Huang 等人探讨了不同透明度设计对用户系统策略理解和信任的影响^[60]；Niu 等人考察了拟人化元素在界面设计中的有效性^[61]；Rezvani 等人则重点研究了如何通过传达内部和外部系统意识来增进驾驶员对辅助驾驶系统的信任^[62]；Okamura 等人探讨了多种透明度信息对无人机操作中人机信任的影响^[63-64]。这些研究基于问卷的方式获取信任值，验证了透明度等设计因素能够有效调控人机信任。

(2) 利用人机信任评估机器性能或调整机器自主控制权限水平。Li 等人构建了结合控制舒适度和决策顺从性的代数信任模型，以推断合适的机器自主性^[38]；Wang 等人基于机械臂协同控制任务需求构建信任模型，用于优化控制性能^[65]；Zahedi 等人则采用简洁的“信任反馈”方案，在多机控制界面上增加额外按钮，让操作员直接标示对每架无人机的当前信任程度，并将信任结果用于编队协同和风险控制^[66]；Guo 等人利用人机信任评估来动态调节无人机间的信息通信权重，以减轻故障无人机对整体性能的负面影响和人类的控制干预^[67]。这些研究成果表明，人机信任指标有助于实现更加高效的人机协同控制。

1.3.4 研究现状总结

综上所述，针对人与搜救无人机的信任建模和协同控制方法研究尚存以下主要挑战：

(1) 信任建模的适用性和可解释性仍有待提升。现有信任模型多基于机械臂、辅助决策等非救援场景下的人机系统，需要进一步完善以适应复杂救援环境中无人机的传感器、通信以及自主避障等能力的动态波动对信任的影响，更好的刻画人机信任的动态演化。此外现有模型仅是将影响因素引入数学框架构建演化方程，缺乏对公式形式、参数物理意义的深入分析，导致模型的可解释性和可迁移性较弱，难以用于搜救无人机的协同控制优化设计中。

(2) 信任调控手段缺乏定量调控策略。当前人机信任的调控手段主要停留在定性分析阶段，通过实验分析不同透明度信息对信任水平的影响。虽然已有研究表明能够通过透明度信息影响人机信任，但缺乏利用信任模型进行实时定量调控的动态策略，从而难以在实时性要求高的系统中确保信任处于合适水平。

(3) 人机协同控制方法仍有待进一步完善。现有人机共享控制策略多聚焦于控制权的动态分配设计，在面对机器高置信度错误时缺乏有效的识别与干预机制，可能导致决策失误并影响系统整体性能。而现有多机任务分配方法普遍假设无人机的执行能力为静态恒定值，未充分考虑救援环境中如传感器故障、通信受限等因素导致的无人机能力波动，降低无人机集群在复杂救援环境下的任务执行质量。

1.4 论文工作内容和结构安排

1.4.1 工作内容

针对上述问题，论文通过构建针对人与搜救无人机协同的定量可计算信任动态演化模型，将人机信任引入到搜救无人机协同控制设计中，实现人类的高级决策能力与机器的自主控制能力的优势互补，最终提升救援任务成功率。具体包括以下三部分内容：

(1) 针对现有信任模型与搜救无人机协同场景的不匹配问题，提出了基于搜救无人机能力的人机信任演化模型。具体包括：针对搜救无人机场景特性，构建考虑无人机多维能力表现和人类认知偏差因子的信任演化模型；分析模型的参数意义和相关理论性能，使模型具备可解释性。

(2) 针对单机协同搜救任务中仲裁策略难以应对机器高置信度错误和人机认知偏差问题，提出了基于信任的自适应仲裁策略。具体包括：设计基于最小化信任偏差的动态透明度策略，利用信任模型预测并选取最优透明度方案，实现人机信任的实时调控，确保信任水平维持在合理范围；构建基于信任的自适应仲裁

机制，根据信任值动态调整机器控制权边界，并结合碰撞风险与信任水平优化人机冲突时的权限平滑过渡，以提升人机协同效率与系统稳定性。

(3) 针对多机协同救援任务中无人机能力波动对分配策略的影响，提出了基于信任的多机任务分配方法。具体包括：构建了涵盖传感器稳定性、通信流畅度、防碰撞能力等的多维能力函数，将人对搜救无人机能力的评估量化为动态信任模型；构建了基于信任和最短时间约束的目标函数，确保环境复杂度高的任务被分配到更高信任的无人机，提升任务成功率；设计了基于信任的锦标赛选择策略，加快遗传算法收敛速度。

1.4.2 结构安排

论文的组织结构如图1.3所示。全文共六章，具体结构安排描述如下：




图 1.3 论文框架

第一章：绪论。介绍搜救无人机在灾害救援中的应用背景，阐述人机协同控制的研究价值，引入人机信任机制的必要性，并总结国内外相关研究成果与不足，明确论文的研究目的和意义。

第二章：相关基础知识。介绍支撑论文研究的核心理论和关键技术，包括强化学习、人机混合控制、意图推理算法和遗传算法，为后续研究提供理论支持。

第三章：基于搜救无人机能力的人机信任模型。研究了搜救无人机协同场景下的信任建模方法，综合考虑无人机多维能力指标和人类认知偏差，构建了具备参数可解释性的信任演化模型。同时，在模型验证中，采用单机共享控制场景中

的“人类引导的救援目标识别”任务作为仿真实验场景，分析信任对人类控制行为的影响。该研究为后续第四章的自适应仲裁策略和第五章的基于信任的任务分配提供模型理论基础。

第四章：基于信任的自适应仲裁策略。研究了在人类引导的救援目标识别任务下，如何避免机器意图推理的高置信度错误以及人类不适当信任对人机协同效能的影响，以及如何利用合适的信任设计人机控制权限分配，提升系统容错率，降低人类控制负载。具体包括基于最小化信任偏差的动态透明度策略、基于信任的自适应仲裁策略、基于信任的单机共享控制框架展示以及仿真实验设计与验证。

第五章：基于信任的多机任务分配方法。研究了多机救援任务中，如何利用人机信任提升任务分配算法对无人机动态能力的感知，以确保任务匹配的合理性。在满足任务对无人机能力的最低要求的前提下，优先分配环境复杂度高的任务给高信任无人机，从而提升整体任务成功率。具体内容包括任务场景描述和问题建模、信任模型构建、基于信任和最短时间约束的目标函数设计、基于信任的改进遗传算法以及算法仿真实验与验证。

第六章：总结与展望。总结研究成果，分析研究中的不足，并展望未来在信任建模、共享控制优化和多机协同任务分配等方向的改进与发展。

第2章 相关基础知识

本章介绍了论文研究涉及的相关概念和基础知识，后续研究基于这些概念展开或提出改进方法。

2.1 强化学习基础理论

强化学习的核心框架是马尔可夫决策过程（Markov Decision Process, MDP），描述了在一系列离散时间步中，智能体如何通过选择不同动作来最大化累积奖励的问题。MDP 可表示为五元组 (S, A, P, R, γ) ：

- （1）状态空间 S ：环境所有可能状态的集合
- （2）动作空间 A ：智能体可执行动作的集合
- （3）状态转移概率 $P(s'|s, a)$ ：从状态 s 执行动作 a 转移到状态 s' 的概率
- （4）奖励函数 $R(s, a)$ ：在状态 s 执行动作 a 获得的即时奖励
- （5）折扣因子 $\gamma \in [0, 1]$ ：平衡即时奖励与长期收益的系数

策略函数 $\pi(a|s)$ 定义了智能体在状态 s 下选择动作 a 的概率分布。如2.1所示，MDP 的目标是找到最大化期望累计奖励的最优策略 π^* 。累计奖励的数学表达式为：

$$G_t = \sum_{k=0}^{\infty} \gamma^k R(s_{t+k}, a_{t+k}) \quad (2.1)$$

其中 γ 越接近 1 表示更重视长期收益。最优策略则通过最大化期望累计奖励确定：

$$\pi^* = \arg \max_{\pi} \mathbb{E}_{\pi} \left[\sum_{k=0}^{\infty} \gamma^k R(s_k, a_k) \middle| s_0 = s \right], \quad \forall s \in S \quad (2.2)$$



图 2.1 强化学习结构示意图

为评估策略性能，需要定义两个核心函数：

- （1）状态值函数：衡量从状态 s 开始遵循策略 π 的期望回报；

$$V^{\pi}(s) = \mathbb{E}_{\pi} \left[\sum_{k=0}^{\infty} \gamma^k R(s_k, a_k) \middle| s_0 = s \right] \quad (2.3)$$

(2) 动作值函数 (Q 函数): 评估在状态 s 遵循策略 π 执行动作 a 后的期望回报。

$$Q^\pi(s, a) = \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k R(s_k, a_k) \middle| s_0 = s, a_0 = a \right] \quad (2.4)$$

根据贝尔曼最优性原理, 最优 Q 函数满足递归关系:

$$Q^*(s, a) = R(s, a) + \gamma \sum_{s'} P(s'|s, a) \max_{a'} Q^*(s', a') \quad (2.5)$$

这一方程为 Q-learning 算法提供了理论基础。

传统 Q-learning 算法通过直接更新 Q 表来逼近最优值函数, 但在面对如视频游戏像素输入的高维状态空间时面临维度灾难。为解决这一问题, 深度 Q 网络 (Deep Q-Network, DQN) 首次将深度神经网络引入强化学习, 提出两项关键技术:

(1) 经验回放 (Experience Replay): 存储转移样本 (s_t, a_t, r_t, s_{t+1}) 并随机采样, 打破数据相关性;

(2) 目标网络 (Target Network): 使用独立网络计算目标 Q 值, 参数定期更新缓解训练不稳定性。

DQN 的损失函数为:

$$\mathcal{L}(\theta) = \mathbb{E} \left[\left(r + \gamma \max_{a'} Q(s', a'; \theta^-) - Q(s, a; \theta) \right)^2 \right] \quad (2.6)$$

然而, DQN 中最大化操作 $\max_{a'} Q(s', a'; \theta^-)$ 会导致系统性高估 Q 值——目标网络和主网络的估计误差会相互叠加, 使得某些动作的价值被过度乐观评估。这一缺陷在动作空间复杂的环境中尤为显著, 可能导致策略收敛至次优解。

为克服 DQN 的高估偏差, 双深度 Q 网络 (Double Deep Q-Network, DDQN) 通过解耦动作选择与价值评估来减少偏差:

(1) 动作选择: 使用当前网络 θ 选择最优动作;

$$a^* = \arg \max_{a'} Q(s', a'; \theta) \quad (2.7)$$

(2) 价值评估: 使用目标网络 θ^- 计算 Q 值。

$$Q_{\text{target}} = R(s, a) + \gamma Q(s', a^*; \theta^-) \quad (2.8)$$

这一改进将目标 Q 值的计算分解为两个独立阶段: 首先基于当前网络参数 θ 确定最优动作 $a^* = \arg \max_{a'} Q(s', a'; \theta)$, 随后通过目标网络 θ^- 评估该动作的价值 $Q(s', a^*; \theta^-)$ 。这种方法成功地解决了 DQN 的过估计问题, 并在多个强化学习任务中表现出更好的性能和稳定性。

DDQN 的训练流程如算法2.1所示:

算法 2.1 DDQN 训练流程

Data: 环境 $\mathcal{E}$, 折扣因子 γ , 初始 ϵ , 缓冲区容量 $|\mathcal{D}|$, 目标网络更新周期 C

Result: 训练后的主网络参数 θ

```

1 随机初始化主网络  $Q_\theta$ , 并令目标网络  $Q_{\theta^-} \leftarrow Q_\theta$ ;
2 创建经验回放缓冲区  $\mathcal{D}$ ;
3 while episode 未终止 do
4     重置环境得到初始状态  $s$ ;
5     while episode 未结束 do
6         以概率  $\epsilon$  随机选动作  $a$ , 否则  $a = \arg \max_{a'} Q_\theta(s, a')$ ;
7         在环境中执行  $a$  获得  $(r, s')$ , 将  $(s, a, r, s')$  存入  $\mathcal{D}$ ;
8         从  $\mathcal{D}$  随机采样  $\{(s_i, a_i, r_i, s'_i)\}$ ;
9          $a_i^* \leftarrow \arg \max_{a'} Q_\theta(s'_i, a')$ ;
10         $y_i \leftarrow r_i + \gamma Q_{\theta^-}(s'_i, a_i^*)$ ;
11        最小化损失  $\mathcal{L} = \frac{1}{N} \sum_i (y_i - Q_\theta(s_i, a_i))^2$ ;
12        if step mod  $C = 0$  then
13             $\theta^- \leftarrow \theta$ 
14        end
15         $s \leftarrow s'$ ;
16    end
17    按设定衰减  $\epsilon$ ;
18 end

```

2.2 人机混合控制方式

AI 驱动的人机协同系统中, 随着机器自主决策能力的提升, 无人机在自主飞行与目标识别方面有着显著的能力表现, 人机协作模式也因此逐步从传统的人类直接控制无人机转变为人机协同控制。在此背景下, 如何合理分配与协调人机之间的自主权成为人机协同系统设计的关键问题。现有研究主要采用共享控制和介入控制作为人机协同系统的基本控制策略, 但学术界对这两种控制模式尚未形成统一的定义。基于相关文献, 论文对共享控制与介入控制的主要特点及适用交互场景进行了归纳, 以明确二者在不同应用环境下的适用性。具体如表2.1所示。

在搜救无人机协同控制中, 介入控制和共享控制的应用场景有所不同。介入控制通常适用于单人监控多架无人机的情境。在这种情况下, 操作员主要通过监控系统状态, 在必要时进行干预, 以确保任务的安全和成功。相对地, 共享控制更常用于单架无人机的飞行控制, 操作员与无人机共享控制权, 共同完成任务, 以优化性能并提高任务效率。

表 2.1 介入控制和共享控制的特点对比

特点	介入控制	共享控制
控制目标	主要关注确保系统的稳定性和安全性，防止人机系统发生不可接受的风险后果。	主要关注系统性能的优化和提升。
系统结构	仅需单方监控对方状态并决定介入时机，无需额外机制。	可能需要设立高于人机的统一“仲裁机构”，负责统筹人机共享策略。
主次地位	人机地位不对等，介入方比被介入方具有更高的决策权。	人机地位平等，不存在某一方的地位始终高于另一方。
相互影响	控制权限可在人与机器之间单向或双向切换。例如辅助驾驶系统可以由人接管机器驾驶，或由机器接管人的驾驶。	人机协同工作，强调深度合作，交互关系更加紧密。
设计要求	介入时机和强度要求严格，错误介入可能导致系统失控。	机制较为复杂，但对决策设计要求更具灵活性，失误多导致优化不足而非系统崩溃。

2.3 意图推理方法

一类传统的人机协同（Human-Robot Collaboration, HRC）系统中，机器的目标是辅助人类完成任务，这要求机器人能够推理人类的意图并提供合理的辅助。因为对机器来说，人机系统中人的意图往往是未知且时变的，若人类无法通过交互界面直接传递意图信息，便需要通过推理算法获取意图从而更好地辅助人类完成任务。在共享控制（Shared Control）场景下，意图推理不仅影响机器的决策能力，还直接关系到人机交互的流畅性：如果机器人频繁推理错误目标，人类需要不断修正其决策，反而增加了操作负担。因此，意图推理的准确性对系统的性能提升至关重要。

意图推理方法可根据推理对象的不同分为目标意图推理和轨迹意图推理^[68]。目标意图推理侧重于推测人类希望机器人最终到达的目标位置或执行的任务，常用方法包括基于贝叶斯推理的方法和基于马尔可夫决策过程或部分可观测马尔可夫决策过程的方法，这些方法通过递归更新目标概率来进行推理。轨迹意图推理则关注人类的运动趋势，通常采用 LSTM^[69] 或 Transformer^[70] 等深度学习模型预测未来一段时间内的运动轨迹，以提升机器人对人类行为的短时预测能力。

在共享控制任务中，人与机器的交互是动态变化的，需要实时调整推理结果。朴素贝叶斯推理因其计算高效、可解释性强，且适用于低维输入信号，成为目

标意图推理中的常用方法。Jain 等人提出的递归贝叶斯推理（Recursive Bayesian Inference, RBI）方法^[71]，基于朴素贝叶斯模型，通过贝叶斯滤波实现动态意图推理。

在该方法中，环境中存在一组离散目标集合 $G = \{g_1, g_2, \dots, g_N\}$ ，其中 $g_t \in G$ 表示时刻 t 的目标状态；观测序列 $O_{0:t} = \{O_0, O_1, \dots, O_t\}$ ， O_t 为时刻 t 的人类输入信号。目标推理的核心是通过递归更新信念状态 $b_t(g) \triangleq P(g_t|O_{0:t})$ ，即基于观测历史的目标后验概率分布。

初始后验概率由贝叶斯定理给出：

$$b_t(g) = P(g_t|O_{0:t}) \propto P(O_t|g_t, O_{0:t-1})P(g_t|O_{0:t-1}) \quad (2.9)$$

其中似然项 $P(O_t|g_t, O_{0:t-1})$ 描述给定目标时观测信号的生成概率，先验项 $P(g_t|O_{0:t-1})$ 表示历史观测下的目标预测概率。由于朴素贝叶斯假设认为各观测变量之间条件独立，可将似然项简化为 $P(O_t|g_t)$ ，进而通过全概率公式展开先验项：

$$b_t(g) \propto P(O_t|g_t) \sum_{g_{t-1} \in G} P(g_t, g_{t-1}|O_{0:t-1}) \quad (2.10)$$

其中 $P(g_t|g_{t-1})$ 代表从时刻 $t-1$ 到时刻 t ，目标从 g_{t-1} 转移到 g_t 的状态转移概率分布，用于建模人类可能更改目标的情况。最终得到递归更新公式：

$$b_t(g) \propto P(O_t|g_t) \sum_{g_{t-1} \in G} P(g_t|g_{t-1})b_{t-1}(g_{t-1}) \quad (2.11)$$

最后通过最大后验概率来确定最可能的人类意图目标：

$$g_t^* = \arg \max_{g_t \in G} P(g_t|O_t) \quad (2.12)$$

当某个目标的概率超过设定阈值，机器人便可开始提供相应的辅助。该算法将预测结果的不确定性表示为置信度，通过计算最有可能的目标与可能性最小目标之间的概率差异表示：

$$C(G) = \max_{g \in G} b_t(g) - \min_{g \in G} b_t(g) \quad (2.13)$$

2.4 遗传算法

遗传算法（Genetic Algorithm, GA）作为典型的智能优化算法，由于使用多点并行搜索，不易陷入局部最优，且能够以编码的方式工作而不直接操作参数本身，因此在无人机集群任务分配中得到了广泛应用^[39,42,72-74]。

遗传算法通过模拟生物进化过程，采用选择、交叉、变异等操作不断优化种群，能够在较短时间内获得高质量的任务分配方案^[75]。在具体应用中，不同的

优化任务会在标准遗传算法的基础上进行针对性的改进，以适应不同任务分配场景。例如 Wang 等人^[73]提出了一种基于对位的双染色体编码遗传算法，用于解决多无人机侦察多类型目标的任务预分配问题。该方法引入了基于对位的学习和多重变异算子，有效提升了求解质量。刘振等人^[72]研究了基于分布估计思想的量子遗传算法，该方法通过建立执行任务的收益、执行时间及任务负载等因素的效能模型，实现了多基地情形下无人机任务的初始分配和突发威胁下的动态分配。Jia 等人^[74]提出了一种基于改进遗传算法的元启发式算法，用于解决多无人机任务预分配问题，该方法能够适应复杂的无人机运动学约束、资源约束与时间约束，提升任务调度的适应性。

因此，论文在此处对遗传算法的核心步骤进行介绍，以便于后续的改进遗传算法设计。遗传算法基本流程如图2.2所示：




图 2.2 遗传算法流程图

（1）染色体编码与种群初始化。染色体编码是指将问题解映射为遗传操作可处理的基因结构，不同问题设计有着不同的编码方式。如二进制编码将离散解转换为二进制串，适用于组合优化问题；实数编码直接使用浮点数表示连续变量，适用于连续型优化问题；排列编码将有限集合内的元素进行排列，适用于旅行商问题。而初始种群可通过随机生成或拉丁超立方采样构建，种群规模通常设置为 50-500，以平衡计算效率与多样性需求。

（2）适应度评估。适应度是评估物种对环境适应程度的标准，反映了个体解决问题的能力。通常适应度高的个体更可能繁衍后代，而适应度低的个体则不易保留。相应的，评估适应度的函数叫做适应度函数，其表达形式一般与优化目标

设置强相关。

(3) 选择操作：基于个体的适应度值，通过特定的选择规则或方法从当前种群中筛选出优良个体，以确保基因能够遗传至下一代。常采用的选择方法有以下几种：

- ① 锦标赛选择：随机选取 k 个个体竞争，保留最优者；
- ② 轮盘赌选择：个体被选概率与适应度成正比；
- ③ 精英保留：保留当代最优个体至下一代，防止优质基因丢失。

(4) 交叉操作：交叉操作是指按照交叉概率随机选择当前种群的个体作为父代，并按照规定使部分染色体基因交换，从而生成新的子代。这种操作模拟了生物遗传进化中的基因重组过程，有助于算法在搜索空间中探索更多潜在解。常用交叉方法有单点交叉、多点交叉、均匀交叉、部分匹配交叉等。其中部分匹配交叉保证了每个染色体中的基因仅出现一次，所以经常被用于旅行商或其他排序问题编码。

(5) 变异操作：变异操作是以变异概率对个体的部分染色体基因执行突变，从而生成新的个体。该操作模拟了生物遗传进化中的基因突变现象，旨在增加种群的多样性，同时具备一定的局部优化能力，有助于算法逼近全局最优解。常用变异方法有位翻转、高斯变异和交换变异等。

(6) 终止条件：当达到预设的迭代次数、适应度阈值或满足其他停止条件时，结束算法，此时的最优个体即为问题的近似最优解。

第3章 基于搜救无人机能力的人机信任模型

考虑到在灾后应急救援场景中，无人机能力表现是多维且动态变化的，本章引入搜救无人机多维能力特征设计了以机器能力为重要影响因素的人机信任模型。具体包括：机器能力的主客观刻画方法和信任动态演化模型、信任演化模型的理论分析与参数估计、仿真实验设计与结果验证。

3.1 引言

现有研究提出人类对机器的信任本质上是两种机器能力之间的关系，这两种机器能力分别为：AI 驱动的机器的实际能力，称为客观机器能力；被人类合作者认可的机器能力，称为主观机器能力。正是机器的客观能力与主观能力之间的差异，导致了人类对机器的不适当信任。因此，本章基于这一概念提出人机信任的可量化定义。

定义 3.1 (机器能力驱动的人机信任) 在 AI 驱动的人机混合智能系统中，设 t 是人机系统运行过程中的任意时刻， $t_0 := 0$ 为系统启动时间， t_k 代表人类第 k 次更新主观机器能力的时间。

基于上述概念，本文将机器能力驱动的人机信任定义为主观机器能力与客观机器能力的比值，具体公式如下：

$$T_m^h(t_k) = \frac{C_m^h(t_k)}{C_m^m(t_k)}, t_k \geq 0 \quad (3.1a)$$

$$T_m^h(t) = T_m^h(t_k), t \in [t_k, t_{k+1}), t_k \geq 0 \quad (3.1b)$$

其中 $T_m^h(t)$ 表示 t 时刻的人机信任， $T_m^h(t_k)$ 、 $C_m^h(t_k)$ 和 $C_m^m(t_k)$ 分别表示 t_k 时刻的人机信任、主观机器能力和客观机器能力。在该定义中，人机信任被视为一个分段常数函数，在两次信任值更新之间保持不变。这种模型不仅符合人类直觉—即信任在没有新的信息或经验的情况下是稳定的，而且也反映了救援场景下任务的阶段性特征，其中信任的变化通常是由特定事件触发的。

为便于后续表述，将人类第 k 次更新信任后的人机信任值简记为 $T_m^h(k)$ ，并将第 k 次更新信任时（ t_k 时刻）的主客观机器能力分别简记为 $C_m^h(k)$ 和 $C_m^m(k)$ 。

定义 3.1 有着以下几点性质：

(1) 与机器能力强耦合：定义将人机信任量化为主观机器能力与客观机器能力的动态比值，有效反映了信任随机器能力变化的过程和对机器潜在的认知偏差，这也是该定义相比于大多数现有定义的优势。

(2) 个性化的信任：在公式 (3.1) 中，通过引入主观机器能力这一概念，将

人的认知差异体现在对机器能力的识别上，从而使得人机信任成为一个个性化的概念，从而在后续系统设计时能更好的发挥作用。

(3) 信任的时变性：该定义很好的捕获了信任的时变性，从而使对信任动态演化进行建模和未来信任值预测等成为可能。

(4) 信任的可计算性：相比于过往将信任定义是人类的一种态度，该定义做到了对人机信任的量化计算，同时，唯一的主观部分，即主观机器能力，也能够通过公式进行量化，从而减少频繁的量表收集对人机系统操作者的干扰。

(5) 明确的过度/缺乏信任：在 t 时刻，信任状态可以根据 $C_m^h(t)$ 与 $C_m^m(t)$ 的大小关系来量化，具体如下：

$$T_m^h(t) \begin{cases} > 1, & \text{当 } C_m^h(t) > C_m^m(t) \text{ 时, 处于过度信任状态} \\ = 1, & \text{当 } C_m^h(t) = C_m^m(t) \text{ 时, 处于正常信任状态} \\ < 1, & \text{当 } C_m^h(t) < C_m^m(t) \text{ 时, 处于缺乏信任状态} \end{cases} \quad (3.2)$$

该定义清晰地展示了不同能力关系下对应的信任状态，能够更直观地对 t 时刻信任的过度、正常和缺乏状态进行量化描述。

在不同的救援任务中，无人机各方面能力表现对人机信任的影响存在差异。比如，在搜救目标引导任务中，人类协作者会更关注无人机的目标推理能力；在穿越障碍物等任务中，人类协作者则更看重其自主轨迹规划能力；在多目标搜救任务中，人类协作者则看重其综合决策能力。为了更好的在 AI 驱动的搜救无人机协同控制任务中刻画人机信任，本章对搜救无人机多维能力进行一般性的量化表述，并基于定义3.1提出机器能力驱动的人机信任模型，通过融合多维能力指标与人类认知因子，实现信任的动态跟踪与可解释建模。

3.2 机器能力刻画

3.2.1 客观机器能力刻画

正如先前所述，在搜救无人机协同控制中，人类操作者通常会依据当前任务关注无人机的一个关键能力指标或整体的混合能力指标。具体而言，考虑到救援任务常常发生在废墟、火灾或极端天气等复杂动态的环境中，对无人机提出以下几点要求：

(1) 传感器稳定性 M_w ：如果无人机在任务中传感器信息出现较大的误差或不稳定表现（例如定位错误、传感器失灵等），会降低人对其判断任务准确性的信任；

(2) 通信流畅度 M_f ：如果无人机的反馈与指令响应延迟过长或通信中断，可能会导致协同效果差，从而影响信任；

(3) 决策可靠性 M_r : 无人机需要具备很强的环境感知与应急决策能力。如果无人机能够在复杂环境下快速适应并做出正确的决策, 人们会更信任其能力;

(4) 防碰撞能力 M_c : 无人机在飞行过程中要避免与障碍物或其他无人机发生碰撞, 以免影响任务进程。

因此可以将机器能力函数表述为如下形式:

$$C_m^m = f(M_w, M_f, M_r, M_c) \quad (3.3)$$

其中 C_m^m 代表机器的能力, $M_i \in [0, 1], i \in \{w, f, r, c\}$ 代表上述能力评估指标, f 表示由 M_i 到 C_m^m 的映射关系。从理论来说, 只要搜救任务是明确的, 并且数学工具足够, 在具体任务中可以针对无人机的某一项或几项能力进行量化衡量, 并设计映射函数 f 以得到当前任务下的机器能力。比如, 在人机协同轨迹跟踪过程中, 无人机位置与预定轨迹的偏离程度与轨迹偏航角、距离障碍物的距离、人类控制指令的响应时间等都可以很好的对任务中的机器各项能力进行量化, 并可以按照对任务的重要性进行加权求和。

在搜救无人机协同搜救任务中, 机器能力评估指标 $M_i, i \in \{w, f, r, c\}$ 通常指 AI 驱动的搜救无人机在决策层和控制层的算法能力, 一般采用神经网络构建。然而, 神经网络的黑盒特性使得人类难以准确衡量机器的能力边界。因此, 许多算法在设计时, 会采用标准数据集中的精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1 Score) 等概率的方式来描述客观机器能力 C_m^m 。在大多数情况下, 作为可批量生产的搜救无人机, 其客观机器能力在人机系统启动前是已知的, 因此, 利用机器能力的先验知识 C_m^m 足以一次性地确定 $C_m^m(t)$, 即公式 (3.4)。

$$C_m^m(t) = C_m^m(0) = C_m^m, \forall t > 0 \quad (3.4)$$

然而, 在实际的人机交互过程中, 搜救无人机所面临的环境具有未知性且在不断变化, 机器能力会受到复杂环境变化的影响而发生波动。比如在面对由障碍物形成的不同大小的通道、不同亮暗的光线、不同的气流变化等复杂环境时, 机器无法做到高质量完成所有情况。因此, 本文将机器在实际交互中的能力表现定义为客观机器能力表现, 记作 $P_m^m(t), t \in (0, +\infty)$, 采用与 $C_m^m(t)$ 相同的评估指标与计量单位进行衡量。 $P_m^m(\Delta k)$ 代表 $t \in [t_{k-1}, t_k)$ 时间间隔内的机器客观能力表现。 $P_m^m(k)$ 为 $P_m^m(t_k)$ 的简写, 代表 t_k 时刻下的客观机器能力表现。

3.2.2 主观机器能力刻画

主观机器能力 $C_m^h(t)$ 代表着人类在交互过程中对机器客观能力的认知程度, 会随着交互的深入而发生变化。作为一个动态演化值, 确定 $C_m^h(t)$ 需要考虑两个阶段, 即初始值 $C_m^h(0)$ 和 $C_m^h(t), \forall t > 0$ 的演化逻辑。

首先, 考虑初始值 $C_m^h(0)$ 。为了保证人机系统的正常运行, 在搜救无人机协同控制任务开始前, 作为机器的操作者和合作方, 人类会被告知机器的客观能力 C_m^m 。人类在初始时刻对机器能力的认知也源于此, 同时人类会基于对该类机器的印象、对机器能力的了解程度等多方面个性化地信任机器。因此, 将人类在系统开始前基于先验知识对机器客观能力的认知程度称为静态认知因子 $a_s \in [0, 1]$, 从而 $C_m^h(0)$ 与 C_m^m 的关系可通过公式 (3.5) 表示。

$$C_m^h(0) = a_s C_m^m \quad (3.5)$$

在人机系统运行过程中, 人通常会随着机器能力表现 $P_m^m(t)$ 的变化而更新对机器能力的认知 $C_m^h(t)$ 。将人类在 $t \in [t_{k-1}, t_k)$ 时间段内感知到的机器能力表现定义为主观机器能力表现 $P_m^h(\Delta k)$, 与 $P_m^m(\Delta k)$ 关系可表示为公式 (3.6)。其中 a_d 代表人类对机器能力表现的认知程度, 称之为动态认知因子。

$$P_m^h(\Delta k) = a_d P_m^m(\Delta k), \forall k > 0 \quad (3.6)$$

假设 3.1 (动态认知因子 a_d 与透明度) 在人机系统运行过程中, 动态认知因子 a_d 代表人类对机器实际能力表现的主观认知程度, 即人类在接收到与机器能力相关的各类信息后, 对机器能力的内化评估程度。在理想状态下, 人类对机器能力的认知程度趋近于机器的真实能力, 即:

$$a_d \approx 1 \quad (3.7)$$

然而, 实际应用中, 系统在界面上呈现的解释性信息——例如轨迹规划路线、飞行稳定性、续航显示等与机器能力密切相关的展示内容 (即“透明度”^[49,76])——会因信息量、展示方式以及术语专业性等因素引发认知偏差, 体现在信任模型中便是参数 a_d 的数值。具体而言:

- (1) 当系统透明度过低时, 人类获取的信息不足, 难以准确捕捉机器能力的变化, 导致对机器能力的低估, 此时 $a_d < 1$;
- (2) 当系统透明度适中且信息精准全面时, 人类能够较为准确地评估机器能力, 但在某些情形下, 可能因过度依赖显示信息而高估机器能力, 从而使 $a_d \geq 1$;
- (3) 当系统透明度过高但信息呈现冗长或包含过多专业术语时, 反而会增加人类的理解负担, 导致信息解读困难, 从而引发认知偏差, 使 $a_d < 1$ 。

因此, 在人机系统的设计与应用中, 合理调控系统透明度不仅有助于提升人类对机器能力的准确认知, 也能够进一步增强系统的信任稳定性和整体控制效果。关于透明度在认知建模和信任机制中的作用, 将在第4.2节中进行更为详细的讨论。

考虑到线性模型能够有效地捕捉和拟合不同操作者在更新主观机器能力时,对当前主观机器能力表现和上一时刻主观机器能力的侧重程度。且线性更新机制在刻画信任与影响因素之间的依赖关系和提升模型可解释性方面具有显著优势,并已被相关研究验证其对不同群体的良好适应性^[54,77-78],因此本文采用线性公式(3.8)表示主观机器能力 $C_m^h(k)$ 的动态更新:

$$C_m^h(k) = (1 - a^*(k))C_m^h(k-1) + a^*(k)P_m^h(\Delta k) \quad (3.8)$$

其中认知更新因子 $a^*(k)$ 代表人类在更新主观机器能力时,对机器能力波动的侧重程度。

公式中考虑上一时刻主观机器能力 $C_m^h(k-1)$ 与当前对机器表现的主观感知 $P_m^h(\Delta k)$,主要基于以下两个方面的考量:一方面,从认知心理学角度来看,人类在评估机器能力时通常具有一定的惯性,表现为倾向于沿用已有认知,即信任具有一定的历史延续性;另一方面,人在观察到机器行为发生显著变化时,会对当前表现产生较强感知,从而影响其对能力的重新判断。上述两个变量分别体现了对历史认知的保留与对当前表现的响应,能够较为简洁地描述人类更新主观机器能力时的基本心理过程。该结构不仅在实际建模中具备较高的计算效率和可解释性,也与已有关于信任动态特征的研究保持一致^[49,78]。

假定 $[t_{k-1}, t_k)$ 时刻内的主观机器能力表现变化值 $\Delta P_m^h(k)$ 和主观机器能力变化值 $\Delta C_m^h(k)$ 可表示为:

$$\Delta P_m^h(k) = P_m^h(\Delta k) - C_m^h(k-1) \quad (3.9)$$

$$\Delta C_m^h(k) = C_m^h(k) - C_m^h(k-1) \quad (3.10)$$

先前的研究^[27]通过实验发现,当人类感知到机器能力上升时,通常会保守地增加自身的主观机器能力,而当机器能力下降时,主观机器能力会产生更显著的下降。将这一观察整理为以下两个假设。

假设 3.2 由于人类对机器能力上升的保守性,当第 t_k 时刻主观机器能力表现 $P_m^h(\Delta k)$ 提升时,主观机器能力 $C_m^h(k)$ 增加的并不明显,即:

$$\Delta C_m^h(k) = a^+ \Delta P_m^h(k), \text{ 若 } \Delta P_m^h(k) > 0 \quad (3.11)$$

其中正向认知更新因子 a^+ 代表人类在遇到机器能力表现提升时会多大程度的提升主观机器能力。

假设 3.3 由于人类对机器能力下降的敏感性和对风险的规避,当第 t_k 时刻主观机器能力表现 $P_m^h(\Delta k)$ 下降时,主观机器能力 $C_m^h(k)$ 下降幅度较大,即:

$$\Delta C_m^h(k) = a^- \Delta P_m^h(k), \text{ 若 } \Delta P_m^h(k) < 0 \quad (3.12)$$

其中负向认知更新因子 a^- 代表人类在遇到机器能力表现下降时会多大程度的降低主观机器能力。

根据假设3.2和假设3.3，可以得到认知更新因子之间的大小关系，即：

$$0 < a^+ < a^- < 1 \quad (3.13)$$

因此，基于公式（3.5）至公式（3.13），主观机器能力的动态演化模型可表示为：

$$\begin{cases} C_m^h(k) = (1 - a^*(k))C_m^h(k-1) + a^*(k)a_d P_m^m(\Delta k) \\ C_m^h(0) = a_s C_m^m, \forall k > 0 \end{cases} \quad (3.14a)$$

$$a^*(k) = \begin{cases} a^+, & \Delta P_m^h(k) > 0 \\ 0, & \Delta P_m^h(k) = 0 \\ a^-, & \Delta P_m^h(k) < 0 \end{cases} \quad (3.14b)$$

3.3 人机信任演化模型

3.3.1 信任演化模型

基于人机信任定义3.1和公式（3.4）与（3.14），初始信任 $T_m^h(0)$ 可表示为：

$$T_m^h(0) = \frac{C_m^h(0)}{C_m^m} = a_s \quad (3.15)$$

而动态信任 $T_m^h(k)$ 则可表示为：

$$T_m^h(k) = \frac{C_m^h(k)}{C_m^m(k)} \quad (3.16)$$

$$= (1 - a^*(k)) \frac{C_m^h(k-1)}{C_m^m} + a^*(k)a_d \frac{P_m^m(\Delta k)}{C_m^m} \quad (3.17)$$

$$= (1 - a^*(k))T_m^h(k-1) + a^*(k)a_d \partial P_k \quad (3.18)$$

其中能力表现因子 ∂P_k 代表 $t \in [t_{k-1}, t_k)$ 时的机器客观能力表现在多大程度上反映了机器客观能力：

$$\partial P_k = \frac{P_m^m(\Delta k)}{C_m^m} \quad (3.19)$$

此外，基于公式（3.1）、（3.6）和（3.9），可以对 $\Delta P_m^h(k)$ 进行重构：

$$\Delta P_m^h(k) = P_m^h(\Delta k) - C_m^h(k-1) \quad (3.20)$$

$$\Delta P_m^h(k) = a_d P_m^m(\Delta k) - T_m^h(k-1)C_m^m \quad (3.21)$$

因此，最终的信任模型可表示如下：

$$T_m^h(k) = (1 - a^*(k))T_m^h(k-1) + a^*(k)a_d\partial P_k, \quad k > 0 \quad (3.22a)$$

$$T_m^h(t) = T_m^h(k), \quad t \in [t_k, t_{k+1}), \quad k > 0 \quad (3.22b)$$

$$T_m^h(0) = a_s \quad (3.22c)$$

其中：

$$a^*(k) = \begin{cases} a^+, & \Delta P_m^h(k) > 0 \\ 0, & \Delta P_m^h(k) = 0 \\ a^-, & \Delta P_m^h(k) < 0 \end{cases} \quad (3.22d)$$

$$\Delta P_m^h(k) = a_d P_m^m(\Delta k) - T_m^h(k-1)C_m^m \quad (3.22e)$$

需要指出的是，本节所提信任模型涉及多个人因参数（包括静态认知因子 a_s 、动态认知因子 a_d 以及认知更新因子 a^* ）。这些参数在设计时均以人类操作者的主观认知特性为基础：静态认知因子 a_s 明确体现了个体在系统启动前基于先验知识对机器能力的主观评估；动态认知因子 a_d 则体现了操作者在实际交互过程中对机器实际能力表现的主观认知程度；认知更新因子 a^* 反映操作者在更新主观机器能力时对机器能力波动的侧重程度。因此，这些人因参数在实际应用时的个性化或群体化属性并非由模型本身的定义严格决定，而是取决于具体的数据来源与研究目标。当模型用于单个操作者时，这些参数能够直接体现个体的认知模式；当模型用于群体分析时，则通过统计方法获得反映群体共性的参数，从而确保了模型在不同分析情境中的灵活性与有效性。

为便于后文表述，本文将该机器能力驱动的人机信任模型记为 MCDTM (Machine Capability-Driven Trust Model)。

3.3.2 模型理论分析

本节对 MCDTM 模型的理论特性进行分析论证，以刻画人机信任在动态交互过程中的演化规律。

性质 1 (MCDTM 模型的收敛性) 在 $a^*(k) \geq a_{\min}^* > 0$ (当 $\Delta P_m^h(k) \neq 0$) 的条件下，信任值将逐渐趋于一个稳态值：

$$T^* = a_d \frac{P_m^m(\Delta k)}{C_m^m} = a_d \partial P_k \quad (3.23)$$

即：

$$\lim_{k \rightarrow \infty} T_m^h(k) = T^* \quad (3.24)$$

证明 定义误差变量：

$$e_k = T_m^h(k) - T^* \quad (3.25)$$

由模型 (3.22a) 与稳态值 (3.23) 可得：

$$\begin{aligned} e_k &= T_m^h(k) - T^* \\ &= (1 - a^*(k)) T_m^h(k-1) + a^*(k) a_d \partial P_k - T^* \\ &= (1 - a^*(k)) T_m^h(k-1) + a^*(k) T^* - T^* \\ &= (1 - a^*(k)) [T_m^h(k-1) - T^*] \\ &= (1 - a^*(k)) e_{k-1} \end{aligned} \quad (3.26)$$

取绝对值得：

$$|e_k| = |1 - a^*(k)| |e_{k-1}| \leq (1 - a^*(k)) |e_{k-1}| \quad (3.27)$$

由假设 $a^*(k) \geq a_{\min}^* > 0$ 可知：

$$1 - a^*(k) \leq 1 - a_{\min}^* < 1$$

因此，不等式 (3.27) 可写为：

$$|e_k| \leq (1 - a_{\min}^*) |e_{k-1}| \quad (3.28)$$

递归迭代得到：

$$|e_k| \leq (1 - a_{\min}^*)^k |e_0| \quad (3.29)$$

由于 $0 < (1 - a_{\min}^*) < 1$ ，故当 $k \rightarrow \infty$ 时，有：

$$(1 - a_{\min}^*)^k \rightarrow 0 \implies |e_k| \rightarrow 0 \quad (3.30)$$

即：

$$\lim_{k \rightarrow \infty} e_k = 0, \quad (3.31)$$

从而得到：

$$\lim_{k \rightarrow \infty} T_m^h(k) = T^* = a_d \frac{P_m^m(\Delta k)}{C_m^m} \quad (3.32)$$

这表明 MCDTM 模型中的信任值将渐近收敛于机器能力表现与机器能力的比值，即信任最终将趋于对机器能力表现因子的主观认知，体现出信任值与机器性能之间的正比关系。 ■

性质 2 (MCDTM 模型的有界性) 设机器能力表现 $P_m^m(\Delta k)$ 有界，即满足：

$$|P_m^m(\Delta k)| \leq M, \quad \forall k \quad (3.33)$$

其中常数 $M > 0$ 。考虑信任动态演化方程 (3.22) 中人因参数 $a_d \in [0, 1]$ 、 $a^*(k) \in [0, 1]$ ，且 $C_m^m > 0$ ，则对任意初始信任值 $T_m^h(0)$ ，信任序列 $\{T_m^h(k)\}$ 满足有界性：

$$|T_m^h(k)| \leq B, \quad \forall k \geq 0 \quad (3.34)$$

其中

$$B = \max \left\{ |T_m^h(0)|, \frac{a_d M}{C_m^m} \right\}. \quad (3.35)$$

因此，当机器能力表现输入有界时，MCDTM 模型的信任输出始终保持有界，保证了系统的稳定性及信任值的合理范围。

证明 利用信任模型的凸组合性质，采用数学归纳法证明。

(1) 初始情况：当 $k = 0$ 时，显然有

$$|T_m^h(0)| \leq B. \quad (3.36)$$

(2) 归纳假设：假设对某 $k - 1 \geq 0$ ，有

$$|T_m^h(k - 1)| \leq B. \quad (3.37)$$

(3) 归纳推导：由模型 (3.22a) 得

$$T_m^h(k) = (1 - a^*(k)) T_m^h(k - 1) + a^*(k) a_d \frac{P_m^m(\Delta k)}{C_m^m}. \quad (3.38)$$

由于 $a^*(k) \in [0, 1]$ ， $T_m^h(k)$ 是 $T_m^h(k - 1)$ 与 $a_d \frac{P_m^m(\Delta k)}{C_m^m}$ 的凸组合。又由 (3.33)，有

$$\left| a_d \frac{P_m^m(\Delta k)}{C_m^m} \right| \leq \frac{a_d M}{C_m^m} \leq B, \quad (3.39)$$

结合归纳假设 $|T_m^h(k - 1)| \leq B$ ，因此凸组合的值满足

$$|T_m^h(k)| \leq B. \quad (3.40)$$

综上，对所有 $k \geq 0$ 均有

$$|T_m^h(k)| \leq B, \quad (3.41)$$

即信任序列有界。 ■

3.3.3 模型参数估计

人机信任演化模型 (MCDTM) 中的静态认知因子 $a_s \in [0, 1]$ 代表着人类在系统启动前，基于先验知识对机器客观能力的认知程度，可通过设计反映机器能力的量表来获取。

针对参数 a^+ （正向认知更新因子）、 a^- （负向认知更新因子）以及 a_d （动态认知因子），采用最小二乘法（OLS, Ordinary Least Squares）基于观测数据来估计。由于 $a^*(k)$ 的具体取值与主观机器能力的波动有关：当人的主观评估提高时， $\Delta P_m^h(k) > 0$ ，此时 $a^*(k) = a^+$ ；当人的主观评估降低时， $\Delta P_m^h(k) < 0$ ，此时 $a^*(k) = a^-$ ；当人的主观评估维持不变时， $\Delta P_m^h(k) = 0$ ，此时 $a^*(k) = 0$ 。因此可以将数据集按 $\Delta P_m^h(k)$ 的符号拆分为两个子集，分别对信任上升和下降情况进行最小二乘回归。

(1) 信任上升数据集 ($\Delta P_m^h(k) > 0$):

$$T_m^h(k) = (1 - a^+)T_m^h(k-1) + a^+a_d \frac{P_m^m(\Delta k)}{C_m^m} \quad (3.42)$$

设 $Y_\uparrow = T_m^h(k)$ ，回归变量 $X_\uparrow$ 为：

$$X_\uparrow = \begin{bmatrix} T_m^h(k-1) & \frac{P_m^m(\Delta k)}{C_m^m} \end{bmatrix} \quad (3.43)$$

待估计参数：

$$\theta_\uparrow = \begin{bmatrix} 1 - a^+ \\ a^+a_d \end{bmatrix} \quad (3.44)$$

使用最小二乘法求解：

$$\hat{\theta}_\uparrow = (X_\uparrow^T X_\uparrow)^{-1} X_\uparrow^T Y_\uparrow \quad (3.45)$$

(2) 信任下降数据集 ($\Delta P_m^h(k) < 0$):

$$T_m^h(k) = (1 - a^-)T_m^h(k-1) + a^-a_d \frac{P_m^m(\Delta k)}{C_m^m} \quad (3.46)$$

设 $Y_\downarrow = T_m^h(k)$ ，回归变量 $X_\downarrow$ 为：

$$X_\downarrow = \begin{bmatrix} T_m^h(k-1) & \frac{P_m^m(\Delta k)}{C_m^m} \end{bmatrix} \quad (3.47)$$

待估计参数：

$$\theta_\downarrow = \begin{bmatrix} 1 - a^- \\ a^-a_d \end{bmatrix} \quad (3.48)$$

使用最小二乘法求解：

$$\hat{\theta}_\downarrow = (X_\downarrow^T X_\downarrow)^{-1} X_\downarrow^T Y_\downarrow \quad (3.49)$$

从回归结果求解参数：

$$\hat{a}^+ = 1 - \hat{\theta}_\uparrow[1], \quad \hat{a}^- = 1 - \hat{\theta}_\downarrow[1] \quad (3.50)$$

$$\hat{a}_d = \frac{\hat{\theta}_\uparrow[2]}{\hat{a}^+} = \frac{\hat{\theta}_\downarrow[2]}{\hat{a}^-} \quad (3.51)$$

因此若 $\hat{a}_d$ 的两个估计值接近，则说明参数估计稳定。

3.4 信任模型实验设计

为验证人机信任模型的有效性,本节以城市住宅区灾后搜救为背景开展实验。本节基于 OpenAI Gym^[79]开发了对应的无人机仿真环境,并采用第1.2节提到的单机共享控制方式,让人类引导无人机前往目标住宅。通过设计合理的仿真实验场景以及机器能力函数,旨在探究所提信任模型的有效性和人机系统中的信任机制,为后续协同控制策略提供设计依据。本章所述实验均在仿真平台上进行,故下文中“实验”一词均指“仿真实验”。

3.4.1 场景描述与仿真设计

城市救援遇道路阻断、人类搜救难以及时抵达时,可采用无人机从空中迅速前往目标住宅,执行搜救任务。执行任务前,人类操作员基于现场信息对可能存在被困人员的房屋进行预判和筛选。操作员可结合居民求救信号、电力/水表变化、社区人口登记信息等,快速判断哪些住宅可能仍有人居住,并初步锁定目标住宅。随后,操作员通过控制引导无人机前往目标住宅入口,无人机通过分析操作员控制行为推理出目标位置,从而辅助操作员进行飞行控制或逐步接管控制权限,减轻操作员的控制负担。这一“人类引导的目标识别”流程有效结合了人类对高层语义信息的理解能力和无人机的精细控制能力,既避免了“挨家挨户”式的低效搜索,也降低了因人类控制经验不足或视角限制引发的碰撞风险。

本节基于 OpenAI Gym^[79]构建了如图3.1所示的无人机仿真环境,该环境提供了一个高度可控且可重复的实验平台,可用于模拟上述任务。如图3.1所示,假定无人机飞行高度固定,从界面下方的起点出发,在人类引导下飞往目标住宅入口。实验中目标住宅的位置由系统随机生成,并通过两条红色高亮线进行提示,该信息仅人可见。无人机可获取地图内所有住宅的相对位置,但不知道目标住宅是哪个,只能通过意图推理算法推理出目标住宅。




图 3.1 无人机控制仿真环境

该场景的状态空间 S 包含：无人机的坐标、速度、倾斜角和角速度，以及目标住宅的坐标，其中目标住宅的坐标信息仅在训练无人机控制算法阶段向机器展示。动作空间 A 为无人机在水平和垂直方向的加速度控制，经编码后形成离散动作集 $\{0, 1, 2, 3, 4, 5, 6, 7, 8\}$ ，从而实现同一时刻有多个维度的控制操作，数字和动作的对应关系见表3.1。奖励函数设计如下： R_1 用于在每步中惩罚速度过快、倾斜角过大、与目标住宅入口之间的距离远等行为； R_2 为终止奖励，只有当无人机与目标住宅入口之间的距离小于一定范围且未发生碰撞才算任务成功，并给予 +1000 奖励，否则视为任务失败，给予 -500 奖励。

表 3.1 动作编号对应关系

垂直方向 / 水平方向	向左加速	不动	向右加速
向上加速	0	1	2
不动	3	4	5
向下加速	6	7	8

为了更好地辅助人类飞往目标住宅入口，采用 DDQN 算法^[80]作为无人机的自主控制算法。在已知目标住宅信息的情况下进行训练，该自主控制算法实现了 95% 的任务成功率。在任务过程中，机器可以实时获取当前窗口内的坐标信息，但并不知道目标住宅是哪一个。人类通过红色高亮线识别确定当前任务的目标住宅并进行控制引导；与此同时，机器根据人类历史控制信息推断目标，辅助人类控制无人机向目标住宅入口靠近。此外，机器的意图推理算法采用 Jain 提出的朴素贝叶斯网络^[81]，训练数据集来源于人工收集的人类操作数据，数据包括每轮实验中的人类决策、目标住宅入口坐标以及飞行轨迹等。在训练结束后，意图推理算法准确率达到 80%。

在此任务中，人类和 AI 驱动的自主控制算法共同参与对无人机的飞行控制。系统最终控制输出可表示为：

$$u_s = u_h \cdot (1 - \eta) + u_m \cdot \eta \quad (3.52)$$

其中 u_h 表示人类控制决策输入， u_m 表示机器控制决策输入， u_s 是发送给机器的最终控制决策。权限因子 η 决定了人类和机器之间控制权限的划分，其值基于意图推理结果的置信度 κ_r 进行设计，这也是被广泛采用的一种权限分配方案^[81-83]。

η 的值函数具体可表示为：

$$\eta = \begin{cases} 0 & \text{if } \kappa_r < \zeta_1 \\ \frac{\zeta_3(\kappa_r - \zeta_1)}{(\zeta_2 - \zeta_1)} & \text{if } \zeta_1 \leq \kappa_r \leq \zeta_2 \\ \zeta_3 & \text{if } \kappa_r > \zeta_2 \end{cases} \quad (3.53)$$

其中置信度 κ_r 用于衡量算法当前预测的准确性。当 κ_r 超过下限阈值 ζ_1 时，机器的控制权限与 κ_r 成比例地增加，直到它超过上限阈值 ζ_2 ，此时它提供由 ζ_3 定义的最大帮助。 $\zeta_i, i = 1, 2, 3$ 的取值通过经验确定，在本实验中分别为 $\zeta_1 = 0.3$, $\zeta_2 = 0.7$, $\zeta_3 = 0.8$ 。

3.4.2 机器能力函数

在人类引导的搜救目标识别任务中，操作者主要关注机器的意图推理能力可靠性 M_r 与飞行过程中的防碰撞能力 M_c 。因此将机器能力函数定义为：

$$C_m^m = \sigma_1 M_r + \sigma_2 M_c \quad (3.54)$$

$\sigma_1, \sigma_2 \in [0, 1]$ 分别代表对意图推理能力与防碰撞能力的侧重程度，且满足 $\sigma_1 + \sigma_2 = 1$ 。

第 i 次任务中，机器意图推理结果 $\rho_r(i)$ 依据目标预测与实际目标之间的欧几里得距离 δ_i 判定。当 $\delta_i < \epsilon$ 时，推理成功， $\rho_r(i) = 1$ ；反之当 $\delta_i \geq \epsilon$ 时，推理失败， $\rho_r(i) = 0$ ，即：

$$\rho_r(i) = \begin{cases} 1, & \text{若 } \delta_i < \epsilon, \\ 0, & \text{若 } \delta_i \geq \epsilon. \end{cases} \quad (3.55)$$

同理第 i 次任务中的防碰撞结果 $\rho_c(i)$ 根据在时间区间 $[t_{i-1}, t_i]$ 内是否发生碰撞来确定：

$$\rho_c(i) = \begin{cases} 1, & \text{若在 } [t_{i-1}, t_i] \text{ 内未发生碰撞,} \\ 0, & \text{若在 } [t_{i-1}, t_i] \text{ 内发生碰撞.} \end{cases} \quad (3.56)$$

考虑到人类在交互过程中对近期体验更为敏感，即当前机器能力表现对信任建立有着更直接的影响，同时历史能力表现也会影响人类对机器的整体信任^[49]，采用带遗忘机制的动态加权策略来设计意图推理能力可靠性函数 M_r （防碰撞能力 M_c 同理）。具体来说，设定移动时间窗口 N 并采用指数衰减的权重分配以确保最新的数据赋予更高权重，且历史数据也不会完全被忽略，从而兼顾当前表现与历史积累对信任的影响。其定义为：

$$M_r(k) = \begin{cases} \frac{\sum_{i=\max(0, k-N+1)}^k \lambda_r^{k-i} \rho_r(i)}{\sum_{i=\max(0, k-N+1)}^k \lambda_r^{k-i}}, & k > N, \\ \frac{\sum_{i=0}^k \lambda_r^{k-i} \rho_r(i)}{\sum_{i=0}^k \lambda_r^{k-i}}, & k \leq N. \end{cases} \quad (3.57)$$

类似地，防碰撞能力 M_c 定义为：

$$M_c(k) = \begin{cases} \frac{\sum_{i=\max(0, k-N+1)}^k \lambda_c^{k-i} \rho_c(i)}{\sum_{i=\max(0, k-N+1)}^k \lambda_c^{k-i}}, & k > N, \\ \frac{\sum_{i=0}^k \lambda_c^{k-i} \rho_c(i)}{\sum_{i=0}^k \lambda_c^{k-i}}, & k \leq N. \end{cases} \quad (3.58)$$

其中衰减因子 λ_r 和 $\lambda_c \in (0, 1)$ 。这种设计一方面保证了当前的机器能力表现能够以更高的权重反映在评价中，另一方面也将历史能力表现纳入考量，从而更全面地反映人类对机器的信任形成过程。

3.4.3 仿真实验设置

本次实验关注两项关键能力指标：意图推理能力 M_r 和防碰撞能力 M_c 。这两项能力的计算均基于指数衰减加权策略以反映近期表现对整体评价的影响，且意图推理能力在任务中更为重要，因此二者在机器能力评估中的权重分别为 $\sigma_1 = 0.6$ 和 $\sigma_2 = 0.4$ ，移动时间窗口 $N = 10$ 。

为了评估 MCDTM 模型的有效性，在校内随机招募了十名平均年龄 25 岁的操作者实验。他们使用键盘上的方向键控制无人机在水平和垂直方向上的加速度大小，并在正式实验开始前完成 20 次练习试验以熟悉界面。在被告知 AI 驱动的无人机的理论能力和实验详细设置后，操作者结合练习试验的体验从 [0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0]（0.1 代表非常不信任，1 代表完全信任）中选择对机器能力的初步主观认知，从而得到初始的信任值。

在实验过程中，每位操作者首先需完成 200 次交互实验，以收集信任数据；随后采用节 3.3.3 中介绍的方法，对每位操作者的信任模型参数进行估计。接下来，操作者将再进行 100 次交互实验，以便对比信任模型预测值与真实信任数据。每次交互实验结束后，系统会自动以问卷的形式邀请操作者在 (0.1 ~ 1.0) 范围内对机器的主观能力进行评价，同时自动记录本次实验中操作者在控制回路中的控制频次、无人机是否发生碰撞、是否到达指定目标住宅区域、完成任务所用时间等关键数据。因此将每次交互实验结束时刻定义为人机信任更新时刻 t_k 。

3.5 实验结果分析

3.5.1 信任模型验证

在参与实验的操作者中选取具有代表性的四位，对其信任量表值与所提 MCDTM 模型信任值的动态变化进行展示，并用虚线标注信任的平均值。如图3.2所示，两种信任变化曲线差值较小，且平均值接近，可以看出所提方法能够很好的跟踪操作者对搜救无人机的信任变化，验证了所提方法的有效性。表3.2中展示了四位操作者信任模型的参数值，结合图3.2可以发现，操作者的信任平均值与 a_d 参数值接近，这说明人类对搜救无人机的总体信任会受到人类主观认知程度的影响，这一认知程度与机器真实能力的偏差越大（即 $|a_d - 1|$ 越大），人机信任值与机器能力的偏差也就越大。




图 3.2 不同操作者的信任量表值和 MCDTM 模型值

表 3.2 四位操作者的信任模型参数值

操作者编号	a^+	a^-	a_d
1	0.1344	0.2543	0.7432
2	0.1801	0.3121	0.8632
3	0.1844	0.3243	0.9432
4	0.2244	0.3843	1.043

通过随机方式选取一名操作者的实验数据，并对其结果进行展示。如图3.3所示，实验数据表明：

(1) 机器意图推理能力 M_r 和防碰撞能力 M_c 随时间步 k 变化呈现一定波动, 表明无人机的能力确实会受到环境、人类操作、算法不确定性等的干扰而发生变化。因此在信任设计过程中考虑机器的动态能力表现是有必要的。

(2) 由于在实验过程中若意图推理失败, 机器的错误决策可能会导致无人机飞往其他区域, 增加碰撞风险。此外人类非有效操作的引入也会增加机器维持自身稳定的难度。在图3.3中表现为机器防碰撞能力 M_c 曲线与 M_r 曲线存在一定耦合, 且机器防碰撞能力 M_c 均值为 0.78, 低于机器自主飞行过程中的防碰撞能力 (0.95)。




图 3.3 MCDTM 模型的信任量表值与模型值

从图3.3中 MCDTM 信任模型值 T_{model} 曲线和信任量表值 T_{value} 曲线的对比进一步看出信任模型能够有效的对信任量表值进行跟踪, 且信任量表值和模型值的均方误差为 1.8×10^{-4} , 证明了 MCDTM 模型的准确性和可靠性。

此外, 通过对比机器能力表现曲线 P_m^m 和信任量表值 T_{value} 曲线可以看出:

(1) 信任能够有效的跟踪机器能力表现 P_m^m 。不论是 $T_{value}(k-1) > P_m^m(k)$ 还是 $T_{value}(k-1) < P_m^m(k)$, 信任量表值 $T_{value}(k)$ 都会逐步递归至 $P_m^m(k)$ 附近, 验证了定义1中所述的信任值将趋近于与机器能力相关的稳定值 T^* 的有效性。

(2) 当机器能力表现曲线 P_m^m 有界时, 信任量表值 T_{value} 也有界。图中机器能力表现值 P_m^m 的范围为 $[0.49, 1]$, 而信任量表值 T_{value} 的范围为 $[0.61, 0.99]$, 验

证了定义2中所述的信任序列有界性。

3.5.2 信任与人类控制频次

第1.2节在描述单机共享控制场景时提到，人类会在认为机器推理出目标区域并能够自主完成后续飞行任务的情况下脱离共享控制过程，即人类信任机器能力足以完成后续任务。因此本节对每轮实验中人类在共享控制过程中的控制频次和人机信任之间的关系进行分析。

为了更好的进行分析，将信任分为 10 个区间：

$$\Delta T_n = [0.1 \times (n - 1), 0.1 \times n] \quad \text{其中 } n \in \{1, 2, \dots, 10\}. \quad (3.59)$$

在利用四分位距（IQR）法对异常实验数据剔除后，每个信任区间 ΔT_n 内的人类操作者控制频次 f_n 可以用在该区间内的平均值进行表示，具体数据如图3.4所示。




图 3.4 人机信任与控制频次的关系

从图3.4中可以看出，当人对机器能力的信任程度越高，人类频繁参与控制引导行为的意愿越低，且这一过程是非线性的。这主要由意图推理的算法的原理决定，实验采用的推理算法^[81]通过对人类的控制决策行为进行分析得到可能的目标区域概率分布，并选取其中概率最高的区域作为人类目标区域。在人类被告知机器在已知目标住宅位置的情况下自主飞行的成功率可达 95% 后，人类操作者更倾向由机器自主完成后续实验以避免人类可能存在的操作失误。因此，当人类通过观察无人机飞行轨迹判断机器已获得足够输入能够正确预测出目标时，会立即停止控制输入，转而变为监管者。

图3.5展示了不同信任区间下任务的成功率和失败率。可以发现，当人类信

任较低时,由人类控制导致的坠毁率占比较高,主要是在低信任情况下,人会更多的参与到共享控制过程中,但相比于更擅长精细控制的算法,人利用键盘进行的控制行为无疑更粗糙,甚至带来不必要的干扰,从而增加了无人机的坠毁。当信任逐渐升高时,由人引起的坠毁开始减少,但相应的,由意图推理而导致的任务失败率开始升高,其背后原因是人类的控制决策的减少导致算法未能准确捕捉人类目标意图。总体而言,当信任区间处于 ΔT_9 时任务的整体成功率最高,这也体现了在人机混合控制系统中考虑信任的必要性。




图 3.5 不同信任区间下各类任务结果占比分布

3.5.3 信任影响机理与设计启示

上述实验数据和分析揭示了人机信任在单机共享控制任务中的影响机理:在人类引导的目标识别任务中,人类的信任程度与在共享控制中的参与意愿之间存在反比关系。具体而言:

(1) 人类越是过度信任机器,越会减少在共享控制中的控制频次,导致机器意图推理错误率上升,无法完成任务;

(2) 人类越是不信任机器,越会增加在共享控制中的控制频次,不仅增加人类的操作负担,也会导致机器碰撞风险上升。

因此在搜救无人机与人类协同过程中,保持合适信任水平十分重要。在第四章中,会基于该机制进行相应的控制设计,以确保在搜救无人机协同控制中人类能够保持合适的信任水平。

3.6 本章小结

本章提出基于搜救无人机能力的人机信任模型（MCDTM），通过融合无人机多维动态能力与人类认知偏差，构建了分段递归的信任演化方程，并从理论层面验证了其收敛性与有界性。实验表明，模型可有效跟踪信任演化趋势，并揭示了信任水平对协同行为的非线性影响：过度信任导致机器自主决策风险增加，低信任引发人类频繁干预与系统稳定性下降。结论指出需通过动态调控策略平衡人机协作效能，为后续信任驱动的协同控制方法设计提供理论支撑。

第4章 基于信任的自适应仲裁策略

在人类操作员引导搜救无人机飞往救援目标的单机共享控制场景中，信任偏差会显著影响控制效能；同时，不恰当的权限分配可能导致机器出现高置信度错误时，人类操作者难以及时修正控制决策。因此，本章提出了基于信任的自适应仲裁策略。具体包括：基于最小化信任偏差的动态透明度策略、基于信任的自适应仲裁策略、基于信任的单机控制框架展示、仿真实验设计与结果验证。

4.1 引言

第3.5.3节通过分析实验结果指出，过度信任会导致机器推理错误率上升，而低信任则引发人类频繁干预，降低系统稳定性。因此在控制设计中引入信任偏差管理，特别是通过动态透明度策略最小化信任偏差，是确保系统高效稳定运行的关键。

此外，实验过程中发现 Jain 提出的权限分配方法^[81]存在局限性。该方法使用意图推理成功率和算法置信度来确定机器在共享控制中的控制权限。这种被广为接受的权限分配方法会按算法置信度的高低为机器分配控制权限的大小，置信度越高，机器获得的控制权限越大^[82-83]。然而，这会导致当推理算法出现高置信度错误时，人类因为权限受限难以及时纠正。因此，需要一种更适当的方法来划分人机控制权限。

4.2 基于最小化信任偏差的动态透明度策略

4.2.1 信任认知路径与透明度作用

在搜救无人机协同控制系统中，无人机集群需要深入地震废墟、火场核心区等高风险未知环境执行目标搜寻、伤员定位、紧急物资投送等任务。如图4.1所示，由于危险区域的不可进入性，人类操作者通常位于数公里外的指挥中心，通过交互界面与遥控设备对远端无人机进行跨空间监控与控制。这种人机物理空间分离的特性导致人类操作者对机器能力的认知呈现双重路径：

(1) 任务执行层面的客观绩效反馈：操作者通过任务周期内的关键绩效指标，如救援目标探测的漏检率、飞行过程中是否零碰撞、任务完成的时效等评估无人机系统的基础能力。

(2) 交互界面传递的解释信息：在任务执行过程中，操作者通过界面呈现的无人机飞行状态与决策依据等了解机器能力，包括但不限于无人机的轨迹规划信息、目标识别的结果置信度、信号延迟信息等。



图 4.1 搜救无人机协同控制系统框图

现有研究将此类解释性信息定义为机器透明度，即“界面的描述性质量，即界面在帮助操作员理解智能代理的意图、表现、未来计划和推理过程等方面的能力”^[59]。在搜救任务中，包含机器能力解释的透明度不仅影响操作者对无人机的静态能力评估，更能影响操作者对机器动态可靠性的判断。同时，已有研究指出，通过在适当的时机向操作者提供不同等级的透明度信息，能够有效地帮助操作者识别自身过度信任或信任不足的状态，实现人机信任的自适应调节^[64]。且相比于持续提供的静态透明度信息，这种动态透明度能够更有效地纠正操作者的不适当信任倾向，提升人机系统在任务执行过程中的安全性和决策效率。

如图4.2所示，机器透明度信息根据现有研究可大致分为视觉、听觉、文本和拟人化这四类：

（1）视觉透明度信息：视觉信息通过图形界面或可视化元素展示机器状态、及不确定性等内容。例如，在交互界面上以图形形式显示传感器准确度和算法不确定性，能够让操作者直观了解系统的可靠性，从而及时调整信任。Helldin 等人的研究表明，在半自动系统中，提供传感器精度和不确定性等视觉信息不仅提高了操作者对自动化系统的信任，还改善了任务绩效^[84]。在救援任务中，视觉信息具有直观、易读的特点，能够帮助操作者在短时间内捕捉关键信息，但设计时仍需确保图形呈现简洁，以防增加不必要的认知负担。

（2）听觉透明度信息：听觉信息主要通过声音提示或音频警报传达系统状态，如警报音或语音提醒。在系统性能下降或发生异常时，音频提示能迅速吸引操作者的注意。Okamura 和 Yamada 的实验发现，音频提示（例如语音提醒）在机器恶化时能够促使操作者降低对系统的信任^[64]。然而，考虑到救援现场常伴有大风、设备噪音等干扰，听觉信息的辨识度容易受影响；同时，较长的语言提示会增加操作者的认知负担。因此，在这种嘈杂且复杂的环境中，听觉透明度信

息的应用效果受到明显限制。

(3) 文本透明度信息：文本信息通过直接的文字描述传达机器内部状态、决策依据或算法置信度等内容。界面上对算法结果的置信度、决策依据进行明确说明，能够帮助操作者理解机器的决策过程。已有研究表明，当操作者认可决策依据时，其对机器的信任水平会随之提升；反之，则会降低^[51,64,84-85]。文本信息不仅可以提供详细且明确的解释，而且便于在视觉信息不足以传达全部细节时进行补充，但设计时也需注意避免冗长复杂，防止造成认知负担过重。

(4) 拟人化透明度信息：拟人化信息采用拟人化图标或角色来传达透明度信息。例如，Niu 等人在共驾交互界面中采用眼睛图标来表示机器控制状态，其结果显示拟人化设计有助于提升操作者对机器的信任^[61]。然而，Okamura 等人的研究指出，仅依靠拟人化图标的提示效果不及明确的文本提示^[64]；同时，Roesler 等人的研究进一步表明，在任务驱动的人机交互过程中，拟人化信息主要影响操作者对智能机器的态度，而对实际交互行为的改善作用有限^[86-87]。因此，在紧急且高效率要求的救援任务中，拟人化信息更多起到辅助作用，其在直接传达关键信息上的效果相对不足。




图 4.2 透明度信息示意图

综上所述，考虑到救援任务现场存在大风、设备噪音及复杂的人员沟通等多重干扰因素，同时操作者需要在短时间内准确捕捉并处理信息作出决策，视觉透明度信息凭借其直观、快速的信息呈现优势和文本透明度信息通过详细说明辅助人类理解的特点，在该情境下更具实际应用价值。相比之下，听觉透明度信息受环境噪声影响较大，而拟人化透明度信息虽有助于塑造整体良好印象，但在提升实际交互效率上存在局限性。因此，本章在搜救无人机协同任务环境中提出采用视觉与文本透明度信息相结合的动态透明度策略，以期在确保信息传达清晰的前提下提升人机协同效率。

4.2.2 三级透明度界面设计

在人类引导的救援目标识别任务中，透明度机制旨在帮助操作者更准确、全面地理解无人机在意图推理能力 M_r 和防碰撞能力 M_c 两个方面的实际表现，从而对机器信任水平进行合理动态调节。考虑到任务执行过程中，操作者尤为关注以下信息：

- (1) 推理结果是否准确；

- (2) 推理算法结果的置信度;
- (3) 推理算法最近一段时间的平均准确率;
- (4) 机器发生碰撞的概率。

为了满足上述需求,设计了低、中、高三种透明度信息等级 τ ,以便在适当时机向操作者提供不同层次的提示信息,实现人机信任的动态调控:

(1) 低透明度 τ_l : 仅展示机器当前时刻的意图推理结果,采用色块在画面中标记出推理出的目标位置,不附加其他解释或数值信息。

(2) 中透明度 τ_m : 在显示意图推理结果的基础上,通过数值可视化方式实时展示关键指标。将意图推理结果的置信度以及机器发生碰撞的概率以柱状图的形式呈现,反映当前状态的数值变化,使操作者能够直观捕捉机器能力的动态变化。

(3) 高透明度 τ_h : 除实时显示数值信息外,辅以文本提示,说明变化原因及历史表现情况:

- ① 当操作者决策过多导致碰撞概率上升时,提示:“建议您减少控制决策输入,以免引发机器碰撞。”
- ② 当操作者决策输入不足而影响推理准确性时,提示:“目前推理算法平均准确率较低,建议操作者增加控制决策输入。”
- ③ 当推理算法出现故障时,提示:“当前推理结果的可信度较低,建议操作者审慎评估当前推理结果。”

在设计高透明度时,减少了晦涩专业术语的表达,确保文本信息简洁明了,以免增加人类的认知负担。

意图推理算法的置信度 κ_r 常被定义为目标概率分布中最大概率与最小概率之差^[88]。考虑到机器发生碰撞的概率 κ_c 与机器当前速度 v 、与障碍物之间的最短距离 d 以及机器最大减速度 $a_{\max}$ 有关,将其定义为在最大减速度下将当前速度 v 降至零所需的最小刹车距离 s 与障碍物之间的最短距离 d 的比值。具体来说,根据经典运动学公式,当以恒定减速度 $a_{\max}$ 制动时,从速度 v 刹车至零所需的最小距离为:

$$s = \frac{v^2}{2a_{\max}} \quad (4.1)$$

因此定义碰撞风险为:

$$\kappa_c = \frac{s}{d} = \min\{1, \frac{v^2}{2a_{\max}d}\} \quad (4.2)$$

该公式表明,当以最大减速度制动时,如果所需的刹车距离 s 超过了与障碍物之间的距离 d (即 $\frac{v^2}{2a_{\max}d} \geq 1$),则碰撞风险被认为是最高的(即 $\kappa_c = 1$);否则,碰撞风险按比例计算,并将其值限制在 $[0, 1]$ 范围内。

在信任模型构建中已将透明度对人机信任的影响形式化为与动态认知因子 a_d 相关的假设 3.1。即以上三种透明度等级通过不同程度的信息呈现，能够对 a_d 进行调节，从而使操作者在相同客观机器能力下，对机器能力形成不同的主观认知。为简化表述，记：

$$a_d^*(k) = \begin{cases} a_d^l, & \tau = \tau_l \\ a_d^m, & \tau = \tau_m \\ a_d^h, & \tau = \tau_h \end{cases} \quad (4.3)$$

其中 τ_l, τ_m, τ_h 分别表示低、中、高三种透明度水平； a_d^l, a_d^m, a_d^h 对应在这三种透明度下操作者的动态认知因子取值。

4.2.3 透明度对动态认知因子的影响实验

为了进一步量化不同透明度等级对信任模型演化的影响，从而完成最小化信任偏差策略的设计。本节通过人机交互实验探讨三种透明度等级对人类动态认知因子的值影响。

4.2.3.1 仿真实验设置

本节沿用第3.4.1节中构建的无人机仿真环境来模拟“人类引导的目标识别”任务场景，并在保留其物理模拟功能的基础上，利用 Pygame 的绘图函数对交互界面进行了自定义可视化设计。新增了色块、文本框、柱状图等透明度元素，从而确保界面风格与原环境保持一致并可随仿真状态实时更新。图 4.3 展示了分别对应低、中、高三种透明度等级的示例界面。

为评估不同透明度信息对信任动态认知因子 a_d 的影响，参与者在开始正式实验前完成了六轮预实验，以便参与者熟悉人机交互界面与三种透明度等级。随后，在正式实验中，参与者分别在低、中、高三种透明度条件下各执行 100 次实验任务，透明度等级的呈现顺序随机分配，并在其间安排短暂休息，以尽量消除先后顺序、个人经验和疲劳等干扰因素。实验过程中，参与者通过键盘方向键操控无人机前往指定目标区域，每次任务结束后，系统会自动弹出信任问卷窗口，要求参与者提交即时的信任值，并同步记录本轮任务的机器表现、透明度水平等数据。

4.2.3.2 实验结果与分析

在完成所有实验后，系统记录了参与者在低 τ_l 、中 τ_m 、高 τ_h 三种透明度等级下的机器客观能力表现 P_m^m 以及主观机器能力 C_m^h ，从而得到对应透明度下的人机信任 T_m^h 和能力表现因子 ∂P 的平均值，并采用第3.3.3节提出的模型参数估计方法对不同透明度等级下的动态认知因子 a_d 进行求解。



(a) 低透明度 τ_l ：仅在推理结果位置标记绿色方块，无额外数值说明



(b) 中透明度 τ_m ：在界面右侧用绿色和蓝色柱状图分别显示碰撞概率与推理置信度



(c) 高透明度 τ_h ：在右侧进一步添加文本提示，用于说明人类控制策略建议及机器表现

图 4.3 实验环境中的三种透明度界面示例

结果如表 4.1 所示，当透明度等级由低到高的时， a_d 的数值整体呈上升趋势，且任务过程中的人机信任平均值也整体呈上升趋势。一方面，披露与机器有关的信息有助于操作者形成对机器客观能力的准确认知；且当披露的信息越全面时，操作者对机器的主观认知也就越接近其客观能力。另一方面，全面披露机器意图推理算法和防碰撞概率的信息，使人类能够实时掌握机器的状态，从而更好地完成目标引导和碰撞规避，进而提升系统整体性能，这一点可以从机器能力表现因

子 δP 的平均值随着透明度等级提升而进一步增大的现象中看出。此外，注意到在高透明度条件下，人类对机器能力的主观认知略高于机器的实际表现。实验问卷反馈中，参与者表示“全面了解机器在任务中的核心能力表现，使人觉得机器更值得信赖”，而从任务中记录的信任值变化曲线也表明，即使在出现短暂故障时，信任值依然保持在较高水平。

表 4.1 不同透明度等级下的参数值和信任均值

透明度等级	a_d	δP 平均值	T_m^h 平均值
低 τ_l	0.9461	0.8718	0.8078
中 τ_m	0.9859	0.9388	0.9077
高 τ_h	1.043	1.018	1.047

为探究透明度如何随时间影响人机信任动态变化，绘制了参与者在不同透明度等级下的信任变化曲线，如图 4.4 所示。在低透明度条件下，信任曲线 T_m^h 整体低于能力表现因子 δP ，意味着人类未能从机器表现中准确的认知机器客观能力。当机器能力表现发生波动时，信任曲线的变化幅度较大，表明人类对机器的信任极易受到机器临时表现的干扰，难以形成稳定的信任认知。而在中透明度与高透明度条件下，操作者的信任曲线往往维持在较高的区间，曲线波动更平稳。这表明操作者通过接收机器能力相关的解释性信息，能够更好地理解机器的瞬时能力状态与决策过程，从而形成相对稳定、接近真实的信任评估。同时，也注意到在高透明度下，信任曲线 T_m^h 略高于能力表现因子 δP 。这表明人类对机器客观能力的认知高于机器客观能力的实际表现，意味着在多数时间内人类处于过度信任状态。

图 4.4 中不同透明度下能力表现因子 δP 和信任 T_m^h 的平均值虚线进一步佐证了上述结论。随着透明度逐步提升，两条曲线的平均差值逐渐缩小。这表明透明度的增加有助于人类更好地理解机器的能力水平，使人类对机器的认知从最初的模糊、不准确，逐渐过渡到清晰、准确，进而实现对机器能力的精准把握。

进一步对不同透明度下由人引导的目标识别任务的成功率、意图推理失败率和碰撞概率进行分析，将结果绘制在图 4.5 中。需要注意的是，由于图中推理失败率和碰撞概率是分别计算的，因此三种概率之和不等于 1。从图中可以看出，透明度的提升能够显著降低意图推理的失败率和机器的碰撞概率，表明人类能够通过透明度信息判断算法的实时可靠性，从而控制输入较少导致推理置信度较低时保持持续的控制输入，提升推理目标的准确性；在控制输入可能引发碰撞时及时停止控制输入，让机器完成对无人机姿态的精细控制，以免机器碰撞坠毁。自然而然的，人机协同系统在任务中的成功率也相应的有所提升。




图 4.4 参与者在三种透明度下的信任动态变化曲线

结合表 4.1和图 4.4与4.5，可以得出以下初步结论：

(1) 不同透明度等级对 a_d 的调节作用存在显著差异；随着透明度等级的提升， a_d 值逐渐增大，反映出在信息更丰富的情况下，操作者对机器能力形成的主观认知更接近机器客观能力。这与先前对透明度与认知因子关系的假设相吻合。

(2) 在动态任务场景下，高透明度信息有助于保持信任水平的稳定性，使其不会因为偶发的机器失误而出现极端的信任下降波动；而低透明度条件则往往导致更大幅度的信任波动，说明当关键信息缺失时，操作者对于异常事件往往更敏感，易在短时间内大幅调整对机器的信任。

(3) 在动态任务场景下，高透明度信息有助于操作者更好地控制机器，进而提升人机交互系统的综合性能。

综上所述，不同透明度等级在数值层面（如 a_d 参数值的影响与信任平均值）及动态变化层面（信任曲线演化）均展现出明显差异，基本验证了本研究对于透明度与动态信任关系的假设。

4.2.4 最小化信任偏差的透明度选取

基于不同透明度等级对动态认知因子 a_d 的影响，本文设计了一种最小化信任偏差的动态透明度策略，旨在当人机信任 T_m^h 与理想信任值 T_{ideal} 不匹配时，使信任值能够更快地收敛至理想状态；而在 $T_m^h = T_{ideal}$ 时，则保持其稳定。值得注意的是，理想信任值 T_{ideal} 会随救援任务需求而发生变化，一般情况下可取




图 4.5 不同透明度下的人机系统性能

为 1。具体而言，考虑到在实际控制系统中短时段内机器能力的急剧波动较为少见，可假定下一时刻的 ∂P_k 与当前时刻保持不变。对于不同透明度等级对应的动态认知因子候选值 a_d^l 、 a_d^m 和 a_d^h ，在第 k 时刻分别基于信任模型 MCDTM 公式 (3.22) 计算预测信任值：

$$T_{m,i}^h(k) = (1 - a^*(k))T_m^h(k-1) + a^*(k)a_d^{(i)}\partial P_k, \quad i = l, m, h \quad (4.4)$$

进而计算其与理想信任值 T_{ideal} 之间的差值：

$$\Delta_i = |T_{ideal} - T_{m,i}^h(k)| \quad (4.5)$$

选择使得 Δ_i 最小的候选透明度等级，即：

$$i^* = \arg \min_i \Delta_i \quad (4.6)$$

选取的透明度等级 i^* 将作为下一次任务的透明度调节参数，从而实现动态调控透明度信息的披露，逐步消除信任偏差，并使人机信任达到快速且平稳的调整。

4.3 基于信任的自适应仲裁策略

在人类引导的无人机目标识别任务中，系统的最终控制决策 u_s 通过仲裁函数对人工控制决策 u_h 和机器控制决策 u_m 进行动态加权融合，这一过程也被称为控制权限分配。考虑到无人机控制指令的向量空间特性——其本质是三维空间坐标 (x, y, z) 或二维平面投影 (x, y) 的向量运算，采用如下的线性加权融合范式：

$$u_s = u_h \cdot (1 - \eta) + u_m \cdot \eta \quad (4.7)$$

其中仲裁因子 $\eta \in [0, 1]$ 代表在权限分配过程中机器控制输入的权重， η 越大代表最终控制决策越倾向于机器控制决策。

现有研究大多采用意图推理算法在验证集上的准确率和算法置信度来确定机器在共享控制过程中控制权限^[81-83]，即在任务过程中，机器的控制权限会随着算法置信度的升高而逐渐增大，直到机器权限达到设定的阈值。论文第3.4节采用此方法进行权限分配，但在实验过程中发现，此类方法难以应对算法高置信度错误。当推理算法给出有着高置信度但与人类意图不符的目标时，仲裁策略会按照高置信度给予人类较小的控制权限，导致人类即使发现了这一错误，也难以通过控制指令对最终的混合控制决策修正。考虑到适当的人机信任能够真实地反映机器的动态能力表现，本节提出基于信任的自适应仲裁策略（Trust-based Adaptive Arbitration, TBAA），以应对这一问题。

4.3.1 信任-能力耦合的机器控制权边界

首先对第3.4节中基于算法置信度 κ_r 设计的基本仲裁因子函数 η 进行回顾：

$$\eta_{base} = \begin{cases} 0, & \kappa_r < \zeta_1 \\ \frac{\zeta_3(\kappa_r - \zeta_1)}{\zeta_2 - \zeta_1}, & \zeta_1 \leq \kappa_r \leq \zeta_2 \\ \zeta_3, & \kappa_r > \zeta_2 \end{cases} \quad (4.8)$$

式中阈值参数满足 $0 < \zeta_1 < \zeta_2 < 1$ ， ζ_3 表示机器可提供的最大权限。

在救援任务中，人机信任 T_m^h 反映了人类对机器当前能力的实时主观认知，而机器客观能力 C_m^m 则代表了机器在该任务中的实际上限，二者相乘可视为机器“可被接受”的控制权限上限。为确保当机器能力下降时人类能够获得更大控制权，将 η_{base} 的上限 ζ_3 修正为：

$$\zeta_3 \triangleq T_m^h \cdot C_m^m \quad (4.9)$$

若人对机器信任不足（ T_m^h 较低）或机器客观能力不足（ C_m^m 较低），则机器的最大权限会被动态降低，从而降低因机器能力下降而引发的碰撞风险。

4.3.2 基于冲突检测与信任水平的权限平滑过渡

在动态任务中，若人机输入持续出现明显方向性冲突，则说明机器可能发生高置信度推理错误或存在较高碰撞风险。为此，采用以下方式量化两者的瞬时冲突强度：

$$\delta u(t) = \begin{cases} |u_h(t) - u_m(t)|, & \text{若 } u_h(t) \cdot u_m(t) < 0 \\ 0, & \text{其他} \end{cases} \quad (4.10)$$

当两者符号相反且数值差异显著时（乘积为负且差值较大），认为出现冲突。为消除瞬时干扰，采用窗口长度为 W 的移动平均滤波来平滑随机噪声：

$$\overline{\delta u}(t) = \frac{1}{W} \sum_{j=t-W+1}^t \delta u(j) \quad (4.11)$$

若 $\overline{\delta u}(t)$ 超过阈值 δ_{th} ，则记为一次显著冲突；将其累加得到冲突计数 WK 。

当 WK 不低于计数阈值 WN 时，认为人机冲突已达到可疑或危险水平。此时，根据碰撞概率 κ_c 与信任水平 T_m^h 动态调整控制权限：当碰撞概率 $\kappa_c < 0.5$ 时，代表此时碰撞概率较低，冲突主要源于人机意图不一致，因此应逐步收回机器控制权限，转而由人类主导纠正控制策略；当碰撞概率 $\kappa_c \geq 0.5$ 时，代表存在较高碰撞风险，考虑到实验过程中人类的避障与姿态控制能力整体弱于由 AI 算法驱动的机器，因此应逐步削弱人类控制权限，转而由机器主导控制以确保安全性。

鉴于在无人机控制过程中，人类指令和机器机制处于同等地位，当 $(WK - WN)$ 差值相同时，两种情况下的权限衰减速率也应相同。同时，为提升策略的稳定性与鲁棒性，避免因 κ_c 在 0.5 附近微小波动而导致权限目标频繁切换，本文引入迟滞边界 $\varepsilon > 0$ ：当 κ_c 落入迟滞区间 $[0.5 - \varepsilon, 0.5 + \varepsilon]$ 时，权限目标保持不变，仅当其越出该区间时才更新目标方向，确保仲裁方向具有决策惯性。

因此，最终的仲裁因子 η^* 在 $WK \geq WN$ 时，采用以下连续表达式建模权限转移过程：

$$\eta^* = (1 - \lambda^*) \cdot \eta_{base} + \lambda^* \cdot \eta_{tg} \quad (4.12)$$

其中 η_{base} 为依据推理置信度 κ_r 和机器能力上限计算得到的基础仲裁因子：

$$\eta_{base} = \begin{cases} 0, & \kappa_r < \zeta_1 \\ \frac{T_m^h \cdot C_m^m \cdot (\kappa_r - \zeta_1)}{\zeta_2 - \zeta_1}, & \zeta_1 \leq \kappa_r \leq \zeta_2 \\ T_m^h \cdot C_m^m, & \kappa_r > \zeta_2 \end{cases} \quad (4.13)$$

而转移权重系数 $\lambda^* \in [0, 1]$ 表示系统偏离当前权限配置的意图强度，定义如下：

$$\lambda^* = \begin{cases} 1 - e^{-\beta \cdot (WK - WN) \cdot (1 - T_m^h)}, & \kappa_c < 0.5 - \varepsilon \\ 1 - e^{-\beta \cdot (WK - WN) \cdot T_m^h}, & \kappa_c > 0.5 + \varepsilon \\ \lambda_{prev}^*, & \kappa_c \in [0.5 - \varepsilon, 0.5 + \varepsilon] \end{cases} \quad (4.14)$$

其中 λ_{prev}^* 为前一时刻的权重值； $\beta > 0$ 为灵敏度系数，决定转移速率对冲突变化的响应强度。

$\eta_{tg} \in \{0, 1\}$ 表示权限最终目标方向：

$$\eta_{tg} = \begin{cases} 0, & \kappa_c < 0.5 - \varepsilon \\ 1, & \kappa_c > 0.5 + \varepsilon \\ \eta_{prev}, & \text{其他} \end{cases} \quad (4.15)$$

其中 η_{prev} 为前一时刻的目标方向。若碰撞风险低，目标为人类主导；若碰撞风险高，目标为机器主导；若处于迟滞区间，则维持现有权限方向不变。

4.4 基于信任的单机共享控制框架

综合第4.2节在信任感知层面提出的基于最小化信任偏差的动态透明度策略与第4.3节在控制权限分配层面提出的基于信任的自适应仲裁策略，构建如图4.6所示的基于信任的单机共享控制框架。




图 4.6 基于信任的单机共享控制框架

该框架融合了最小化信任偏差、意图推理、强化学习决策、自适应权限仲裁等关键机制，形成如下完整的人机协同决策流程：

(1) 数据采集与信任初始化：实时采集人类历史控制指令序列 $u_h(0, +\infty)$ 、当前信任评估值 $T_m^h(k-1)$ 及机器能力表现 $P_m^m(k-1)$ 。

(2) 目标意图推理：利用公式 (2.11) 中的贝叶斯更新模型计算人类目标意图的概率，并采用公式 (2.12) 选取最大概率目标 g^* 作为强化学习算法的输入。

(3) 机器决策生成：强化学习控制器结合环境状态 s 与目标 g^* ，通过奖励最

大化生成机器控制指令 u_m :

$$u_m = \arg \max_u \mathbb{E} \left[\sum \gamma^t r(s_t, u_t) \right] \quad (4.16)$$

(4) 动态权限仲裁: 仲裁模块接收 u_h 与 u_m , 依据意图推理置信度 κ_r 、碰撞概率 κ_c 及人机信任 T_m^h , 采用公式 (4.12) 计算仲裁因子 η^* , 输出最终指令:

$$u_s = \eta^* \cdot u_m + (1 - \eta^*) \cdot u_h \quad (4.17)$$

(5) 信任预测与透明度调节: 通过 MCDTM 模型计算不同透明度等级 $\tau_i \in \{\tau_l, \tau_m, \tau_h\}$ 的下一时刻信任预测偏差, 从而选择使偏差最小的最优透明度 i^* 。对应透明度信息实时显示于交互界面, 辅助操作者调整信任策略。

该控制框架使系统在信任感知上实时适应操作者的信任变化, 在控制权分配上基于信任实现了对机器高置信度错误的有效纠偏, 解决了传统共享控制中的信任偏差和控制权分配问题, 实现了人机控制权的动态优化与高效协同。

4.5 实验与验证

4.5.1 仿真实验设置

本章采用基于 OpenAI Gym^[79] 二次开发的交互场景验证基于信任的单机共享控制框架的有效性, 环境如图4.7所示, 场景描述与状态空间等信息已在第3.4.1节中介绍。第4.2节详细介绍了交互界面的可视化设计, 通过在环境中加入色块、文本框、柱状图等透明度元素展示针对机器控制决策的解释性信息。



图 4.7 交互场景示意图

每次任务中的目标住宅通过两条红色高亮线进行提示, 高亮线中间的区域代表目标住宅的入口。无人机的前后左右四个方位各有一个推进器, 用于控制在横纵方向上的加速度。参与者通过键盘方向键操控无人机前往指定目标区域, 自适应仲裁策略采用信任模型值进行计算。若无人机安全无碰撞的到达目标住

宅的入口处，则代表任务完成，否则均认为任务失败。机器知道自身的当前位置和环境信息，但无法得知目标住宅的位置。人通过控制输入引导机器前往目标住宅，机器通过人类控制行为推理出目标，并控制无人机飞往对应位置。此外，在交互界面的上方加入了色块，以帮助人类了解当前机器意图推理的结果；在交互界面右侧加入对机器能力相关描述的文本显示和实时数据。

考虑到强化学习驱动的机器控制算法需要大量的数据学习，采用 DDQN 算法让智能机器在该环节中进行单独训练以完成对控制策略的学习，在这一步中机器需要知道目标位置以完成训练。此外，构建了单独人类控制无人机飞往目标住宅入口的数据集，用以训练由朴素贝叶斯网络构成的意图推理算法。实验中的各项参数值设置如表4.2所示。

表 4.2 单机共享控制实验参数设置

参数	值
理想信任值 T_{ideal}	∂P
置信度下阈值 ζ_1	0.3
置信度上阈值 ζ_2	0.7
机器客观能力 c_m^m	0.86
冲突滤波窗口 W	10
机器能力窗口 N	10
冲突阈值 δ_{th}	1
冲突计数阈值 WN	8
灵敏度系数 β	0.8
迟滞边界 ϵ	0.07

本节邀请第4.2节中的参与者继续参与实验，以验证所提出的动态透明度策略的有效性。两项实验间隔为半天，以缓解疲软和经验对实验结果的影响。参与者在未加入信任的单机共享控制策略（无透明度信息且仲裁因子仅与置信度有关）和基于信任的自适应仲裁策略中分别进行 100 轮实验。每次任务结束后，系统会自动弹出信任问卷窗口，要求参与者提交即时的信任值，并同步记录本轮任务的机器表现、透明度水平、任务成功率等数据。

4.5.2 实验结果与分析

本节以纯置信度驱动的共享控制策略作为基准 (baseline) 方法，该策略中机器的控制权限会随着推理置信度的提升而逐渐增加，直到达到最大控制权限 ζ_3 。将基准方法中的 ζ_3 设置为 0.8，与所提 TBAA 方法形成对照。通过对比所提方法

和基准方法在任务下的总体表现来说明所提 TBAA 方法对系统性能的提升；通过对比单一透明度和动态透明度策略下的信任变化曲线来说明动态透明度策略的有效性；通过对比当人机存在冲突时的飞行轨迹来验证所提方法在特殊场景下的有效性。

4.5.2.1 总体表现

在需要人类引导的救援目标识别任务中，机器正确推理目标并成功完成后续任务是关键，在实验场景中表示为机器成功飞往并停留在目标住宅入口处。同时在此过程中，应尽量减少对人类操作者低层级控制的依赖，使其能够将认知资源集中于救援任务的态势感知、多机协同策略制定等宏观决策层面，充分发挥人类在复杂环境判断与应急处置方面的智能优势。因此在评判共享控制策略能力时，考虑系统在任务成功率和人类控制频次两个方面的表现。

实验结果如图4.8所示。图4.8a中展示了所提方法和基准方法在该场景下的成功率，可以看出相比基准方法，所提方法的成功率从 75% 提升至 87%。说明相比纯置信度驱动的共享控制策略，基于信任的自适应仲裁策略在任务成功率上具有更好的性能，这也体现了在共享控制设计中考虑信任的重要性。





图 4.8 单机控制：所提方法与基准方法性能对比

此外，如图4.8b所示，所提方法使人类控制频次降低 19.7%，验证了保持适当信任的必要性。通过给予合适的透明度水平信息，使操作者自适应地根据机器能力参与控制行为，当发现机器表现较差时增加控制频次以确保任务执行成功，当发现机器表现优秀时减少控制频次以减轻自身控制负担。从而将操作者从底层控制中解放，有更多的时间聚焦于救援方案优化与多机任务分配，充分发挥人类在非结构化决策中的智能优势。

上述结果表明，动态透明度策略与仲裁策略的协同作用提升了系统性能。为分析其内在机制，分别从自适应仲裁策略和动态透明度策略两个维度展开分析。

4.5.2.2 自适应仲裁策略

图4.9和4.10展示了当系统发生人机冲突时，不同仲裁策略下的无人机飞行轨迹，设定的飞行区域为 $x \in [-1.0, 1.0]$ 。从图4.9中可以看出，当人类的控制输入会导致无人机快速飞往边界，引发碰撞风险时：若当前意图推理置信度不高，基准方法依旧会给予人类较大的控制权限，从而导致无人机在人类控制下快速飞往边界，直至发生碰撞（如图4.9a）；而所提方法会在检测到碰撞概率上升时，逐渐将控制权限移交给机器，从而避免人类相对较弱的控制决策对系统的干扰，确保了机器的安全飞行（如图4.9b）。



(a) 人类操作导致无人机快速飞往边界

(b) 在无人机靠近边界时移交给机器控制


图 4.9 仲裁策略：存在碰撞风险时的飞行轨迹对比

从图4.10中可以看出当机器意图推理失败（目标位置为 $x = -0.18$ ，推理结果为 $x = 0.55$ ）时：基准方法会基于意图推理算法的高置信度给予机器较大的控制权限，从而导致人类难以通过控制输入纠正机器的高置信度错误，最终无人机未能飞往指定区域（如图4.10a）；而所提方法会在检测到发生人机冲突且碰撞概率较低后，及时将控制权限移交给人类，从而确保人类能够控制无人机飞到正确目标区域（如图4.10b）。因此，当系统发生人机冲突时，自适应仲裁策略相比基准方法有着更优的控制性能。

4.5.2.3 动态透明度策略

系统自动收集了在实验过程中的机器能力表现因子 δP 和人机信任 T_m^h ，前者表示机器表现多大程度上反映了机器客观能力，后者表示人类对机器能力的主观认知。在理想情况下， T_m^h 应该趋近于 δP 。

对实验过程中的 a_d 值曲线进行分析。如图4.11所示，可知基于最小化信任偏差的动态透明度策略会在每个时间步实时计算不同透明度下的信任预测值与理想信任值 T_{ideal} 之间的差，并动态选择使差值最小的透明度等级 τ_i 作为下一次任务中的透明度等级。通过 a_d 曲线的动态波动可以反映出，在任务执行过程中



(a) 无人机在人类控制下稍微向目标区域靠近 (b) 无人机在人类控制下飞到目标区域

图 4.10 仲裁策略：机器高置信度错误下的飞行轨迹对比

采用固定的透明度水平难以在每一时刻都确保人机信任值与理想信任值间的偏差最小，因此需要基于最小信任偏差动态选取合适的透明度等级，从而更好的将信任保持着合适水平。




图 4.11 透明度选取：动态透明度曲线

结合第4.2节中的实验数据，对所提动态透明度策略效果进行分析。如图4.12所示，相比固定透明度策略，所提动态透明度方法能够较好的跟踪 ΔP 的变化，整体误差更小。通过对比图中用虚线展示的 ΔP 和 T_m^h 的平均值，也可以




图 4.12 动态透明度策略：单一与动态透明度下信任曲线对比

发现所提方法二者差值最小，且信任均值在 1 附近，代表机器客观能力与机器主观能力相匹配，证明了所提策略在最小化信任偏差中的有效性。

4.6 本章小结

综上所述，本章提出了基于信任的自适应仲裁策略。考虑到救援场景中环境干扰大、操作者认知负荷重，设计了视觉-文本多模态动态透明度策略。并基于不同透明度等级对动态认知因子 a_d 的调节效应，提出了最小化信任偏差的动态透明度选取策略，并通过实验验证了所提策略能够有效保持人类适当的信任水平。针对机器高置信度错误和人机冲突问题，构建了信任-能力耦合的机器控制权边界和基于冲突检测与信任水平的权限过渡策略，有效解决了高置信度错误场景下的人类控制权不足和人机冲突时的权限平滑过渡问题。仿真实验验证了所提方法的有效性，相较于基准方法，任务成功率从 75% 提升至 87%，人类控制频次降低 19.7%。

第5章 基于信任的多机任务分配方法

针对多机协同救援任务中无人机能力受环境干扰动态波动对分配策略的影响，本章将人机信任作为无人机能力的动态评价指标，提出了基于信任的任务分配方法。具体包括：考虑机器多维能力的信任模型，兼顾任务成功率与执行效率的优化目标函数，基于信任的锦标赛选择策略和改进遗传算法，仿真实验设计与结果验证。

5.1 引言

灾后救援任务中，无人机因其机动性和快速部署能力，在复杂环境下执行搜索、监测与物资投送等任务。然而现实应用中，无人机的能力会受到任务附近的大风环境和电磁干扰等因素导致任务执行精度下降甚至无法完成任务，影响整体救援效率^[89]。如何在多无人机协作任务中有效分配任务，确保关键任务优先由最可靠的无人机执行，是提升整体任务成功率的关键挑战。

现有任务分配方法主要依据无人机的理论物理性能指标（如任务完成时间、能耗等）进行分配，未能充分考虑风扰、电磁干扰等环境因素对无人机能力的影响，难以动态适应无人机能力的变化。考虑到这些信息难以被直接量化，本章将人机信任作为无人机能力评价指标引入到多机任务分配，从而利用操作员基于长期任务反馈形成的认知经验从全局层面优化无人机调度问题，确保关键任务优先分配给高信任的无人机，提升任务成功率。

5.2 场景描述与问题建模

在大型灾后救援中，受困人群聚集地数量较多、运输距离和救援难度也随之增加，单一无人机已难以满足救援物资投递时效性的要求：第一，单一无人机所能承载的电池有限，无法满足长时间的飞行任务，需要频繁返航充电；第二，待救援区域所处环境也不相同，相比地势开阔无遮挡区域，障碍物密集、空间局限区域的救援物资投递任务对无人机能力要求更高；第三，灾后环境存在大风天气导致无人机稳定性降低或密集障碍物导致的通信中断等问题，导致单一无人机在面对复杂环境时能力下降，无法继续完成所分配的任务。因此，多无人机群可以通过救援物资投递任务的能力需求做到针对性的任务分配，实现高效的灾后救援。

如图5.1所示，当地震等自然灾害发生后，城市受灾点多且分散，障碍物为树木、高楼等。在了解不同受灾点的环境复杂度后，指挥中心基于无人机的综合




图 5.1 多无人机救援物资投递场景

能力形成对无人机能力的信任程度，以任务成功率和最短任务执行时间为优化目标为各无人机分配物资投递任务：高信任无人机执行障碍物密集区域的投递任务、中信任无人机负责遮挡适中区域的投递任务、低信任无人机承担地势开阔区域的投递任务。因此，针对救援场景下的多机协同物资投递任务分配策略需具备以下特点：

- (1) 避免碰撞。无人机在飞行过程中不仅要避免与高楼等建筑发生碰撞，还要与其他无人机保持安全距离。
- (2) 分配合理。受伤人群急需救援物资进行伤后处理，因此必须确保无人机有能力完成被分配的投递任务。
- (3) 目标全覆盖。无人机群能够完成所有投递任务，不存在目标区域被遗漏的情况。
- (4) 总体最优。无人机的任务分配策略满足总任务时间最短、任务成功率高等优化目标。

5.2.1 无人机集合

根据运输任务需求,将无人机集合定义为 $U = \{U_1, U_2, \dots, U_n\}$,每架无人机的坐标为 $(U_{i,x}, U_{i,y})$, $i \in \{1, 2, \dots, n\}$ 。由于每架无人机在传感器数量、类型和使用年限等因素的影响下有着不同的能力,进一步将每架无人机的综合能力细化为以下三个能力类别指标:

5.2.1.1 传感器稳定性 M_w

传感器稳定性衡量无人机执行任务时的飞行稳定性，具体反映其在飞行过程中与规划路径的轨迹漂移误差。较大的漂移误差可能会影响无人机对环境信

息的感知精度，从而降低任务执行的可靠性。因此采用指数衰减函数来描述该能力：

$$M_{w,i} = e^{-\lambda_w D_i}, \quad i = 1, 2, \dots, n \quad (5.1)$$

其中 D_i 为第 i 架无人机在任务执行过程中与规划路径的平均轨迹漂移误差（单位：米）； λ_w 为漂移误差对能力影响的衰减系数，值越大衰减越快。

该函数形式保证了当 $D_i = 0$ 时， $M_{w,i} = 1$ ，即无人机完全按照规划路径飞行时，传感器稳定性最高；当 D_i 增大时， $M_{w,i}$ 以指数形式降低，反映出传感器数据可靠性的下降。因此 M_w 的取值范围为 $(0, 1]$ 。

5.2.1.2 通信流畅度 M_f

通信流畅度衡量无人机与控制中心之间的通信质量，直接采用数据包传输率（Packet Delivery Ratio, PDR）作为指标：

$$M_{f,i} = PDR_i, \quad i = 1, 2, \dots, n \quad (5.2)$$

其中：

$$PDR_i = \frac{N_{s,i}}{N_{t,i}} \quad (5.3)$$

$N_{s,i}$ 为第 i 架无人机成功传输到控制中心的数据包数量； $N_{t,i}$ 为第 i 架无人机尝试传输的总数据包数量。

PDR 和通信流畅度 M_f 的取值范围为 $[0, 1]$ ，值越大表示通信越流畅，数据传输的可靠性越高。当 $PDR_i = 1$ 时，表示所有数据包均成功传输，通信质量最佳；当 PDR_i 降低时，表明无人机可能受干扰较大，通信链路存在较高的丢包率。

5.2.1.3 防碰撞能力 M_c

防碰撞能力衡量无人机在飞行过程中与障碍物的安全距离，定义如下：

$$M_{c,i} = \begin{cases} 1, & d_i \geq d_{\text{safe}} \\ \frac{d_i}{d_{\text{safe}}}, & 0 \leq d_i < d_{\text{safe}} \end{cases} \quad (5.4)$$

其中 d_i 为第 i 架无人机在飞行过程中与最近障碍物的最短距离（单位：m）； d_{safe} 表示特定场景下的安全距离阈值，当 $d_i \geq d_{\text{safe}}$ 时，认为无人机无碰撞风险；

防碰撞能力取值范围为 $[0, 1]$ ，值越大表示无人机具备更好的避障能力。 $M_{c,i} = 1$ 表示该无人机在历史任务中一直与障碍物保持安全距离，而 $M_{c,i}$ 低的无人机可能在复杂环境中存在更大的安全隐患。

5.2.1.4 无人机综合能力计算

最终，第 i 架无人机的综合能力 $C_{m,i}$ 通过加权求和计算：

$$C_{m,i} = \alpha_w M_{w,i} + \alpha_f M_{f,i} + \alpha_c M_{c,i} \quad (5.5)$$

其中 $\alpha_w, \alpha_f, \alpha_c$ 为权重系数，且满足 $\alpha_w + \alpha_f + \alpha_c = 1$ 。权重值可依据任务需求或操作者经验进行赋值。例如，在信号较弱的区域，通信流畅度可能被赋予更高的权重，而在环境复杂的情况下，防碰撞能力则更为重要。

5.2.2 任务集合

任务集合可表示为 $TG = \{TG_1, TG_2, \dots, TG_m\}$ ，每个任务间不存在相互依赖，且任务目标位置 $(TG_{j,x}, TG_{j,y})$ ， $j \in \{1, 2, \dots, m\}$ 分布随机。考虑到不同任务区域的环境复杂度对无人机的能力要求差异，设第 j 个任务的复杂度等级为 $w_j \in \{1, 2, 3\}$ ，分别对应低复杂度（I级）、中等复杂度（II级）和高复杂度（III级）环境。参考无人机相关研究^[90-94]，令 $\lambda_w = 4$ ，并给出具体分类标准和能力要求：

（1）I级：地形开阔无遮挡，无显著电磁干扰。如空地、广场。在该环境中，由于环境开阔，路径规划易于执行，偶尔偏离轨迹不会造成较大风险，因此传感器稳定性要求较低，设为 $M_{w,i} \geq 0.4$ ；通信一般而言相对通畅，但考虑到偶发遮挡等因素，仍需维持基本的数据传输可靠性，设为 $M_{f,i} \geq 0.85$ ；由于空间富余，对障碍物保持更大距离是可行的，因此设定较大的安全距离阈值 $d_{\text{safe}} = 1$ 并要求 $M_{c,i} \geq 0.5$ 。

（2）II级：遮挡适中、部分区域存在轻微电磁干扰，如街区之间。在该环境中，由于存在一定数量的障碍，轨迹偏移可能影响任务精度，因此需较高传感器稳定性，设为 $M_{w,i} \geq 0.6$ ；局部通信可能受干扰或遮挡，需确保大部分关键数据能可靠上传，设为 $M_{f,i} \geq 0.9$ ；无人机需要在中等距离下稳定避障，因此安全距离阈值 $d_{\text{safe}} = 0.6$ 并要求 $M_{c,i} \geq 0.6$ 。

（3）III级：障碍物密集、空间局限，如倒塌建筑内部、狭窄巷道。在该环境中，稳定飞行至关重要，较小的轨迹偏移都可能导致碰撞或任务失败，因此传感器稳定性要求最高，设为 $M_{w,i} \geq 0.7$ ；通信链路容易受到遮挡和多路径效应干扰，为确保实时控制和数据回传，需极高的数据传输可靠性，设为 $M_{f,i} \geq 0.95$ ；由于空间局促且障碍物密集，安全距离阈值为 $d_{\text{safe}} = 0.3$ 并要求 $M_{c,i} \geq 0.9$ 。

5.2.3 任务完成时间

考虑到救援任务对完成时间最短的需求，在无人机全程处于最大巡航速度下计算第 i 架无人机前往第 j 个任务目标的完成时间 $t_{i,j}$:

$$t_{i,j} = \frac{V_i}{d_{i,j}} \quad (5.6)$$

V_i 为第 i 架无人机的最大巡航速度， $d_{i,j}$ 为基于路径规划算法得到的第 i 架无人机与第 j 个任务目标之间的路径长度。

5.3 基于信任和最短时间约束的目标函数设计

5.3.1 信任动态演化方程

基于第3.2节提出的人机信任演化机制，操作者通过历史任务反馈与实时交互数据，逐步校准对无人机多维能力的动态评估。设 M_r 表示无人机在某一能力类别上的客观能力，其中 $r \in \{w, f, c\}$ 分别对应第5.2.1中提出的无人机传感器稳定性、通信流畅度和防碰撞能力。鉴于三种能力类别相互独立，本节分别建立对应的信任模型 TM_r ，并给出人机综合信任 T_m 的计算方法。

在先前的公式 (3.14) 中，本文提出了主观机器能力的动态演化方程。由于无人机的能力及其解释信息可通过交互界面实时呈现，操作者可以基于透明度信息更准确地认知机器的客观能力。基于此，本节设定公式 (3.14) 中的动态认知因子 $a_d = 1$ ，从而得到操作者对第 i 架无人机客观能力 $M_{r,i}$ 的信任动态演化方程 (5.7)：

$$TM_{r,i}(k) = (1 - a_i^{r*}(k))TM_{r,i}(k-1) + a_i^{r*}(k)M_{r,i}(\Delta k), \quad (5.7a)$$

$$TM_{r,i}(0) = Ms_r, \quad \forall k > 0. \quad (5.7b)$$

$$a_i^{r*}(k) = \begin{cases} a_i^{r+}(k), & M_{r,i}(\Delta k) > TM_{r,i}(k-1) \\ 0, & M_{r,i}(\Delta k) = TM_{r,i}(k-1) \\ a_i^{r-}(k), & M_{r,i}(\Delta k) < TM_{r,i}(k-1) \end{cases} \quad (5.7c)$$

在任务开始前，操作者的初始信任值 $TM_{r,i}(0)$ 由无人机的理论能力 Ms_r 确定。认知更新因子 a^{r*} 用于衡量人在第 t_k 时刻更新信任时，对无人机在 $[t_k, t_{k-1})$ 时间内的能力表现 $M_r(\Delta k)$ 的权重。具体参数求解方法见第3.3.3节内容，此处不再赘述。

根据公式 (5.5)，可计算无人机的综合信任值 $T_{m,i}$:

$$T_{m,i}(k) = \alpha_w TM_{w,i}(k) + \alpha_f TM_{f,i}(k) + \alpha_c TM_{c,i}(k) \quad (5.8)$$

其中 $T_{m,i}$ 表示第 i 架无人机在人类操作者评价下的综合信任值。

直接采用无人机的综合能力值 $C_{m,i}$ 虽能反映其理论能力, 但该指标通常仅反映出产前的理论表现, 而忽略了长期运行过程中因传感器故障、通信受损等因素引起的能力波动。相比之下, 信任的动态演化模型通过不断更新信任值, 将历史表现与人的主观经验有机融合, 从而更准确地刻画无人机在实际应用中的可靠性与稳定性。此外, 即使试图构建考虑历史能力的综合能力函数, 也难以量化各指标之间的复杂关系以及确定合理的权重。动态信任模型则以更直观、合理的方式整合了这些因素, 从而在任务分配中具有更高的应用价值。

5.3.2 优化模型建立

设无人机任务分配决策变量为:

$$\theta_{ij} = \begin{cases} 1, & \text{若无人机 } i \text{ 执行任务 } j \\ 0, & \text{其他情况} \end{cases} \quad (5.9)$$

将任务执行成本 c_{ij} 定义为无人机完成任务的时间成本:

$$c_{ij} = t_{ij} = \frac{d_{i,j}}{V_i}, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, m \quad (5.10)$$

考虑到优化目标为最大化任务成功率和最短总任务时间, 优化目标函数被定义为:

$$\max \left\{ \sum_{i=1}^n \sum_{j=1}^m T_{m,i} w_j \theta_{ij} - v \sum_{i=1}^n \sum_{j=1}^m c_{ij} \theta_{ij} \right\} \quad (5.11)$$

$\sum_{i=1}^n \sum_{j=1}^m T_{m,i} w_j \theta_{ij}$ 函数表示任务成功的加权信任收益项, 通过赋予环境复杂度较高的任务更大的权重 w_j , 在优化过程中能够优先将高信任值的无人机分配给高复杂度任务。考虑到信任值 $T_{m,i}$ 作为无人机能力的间接量化指标, 值越高通常表明其执行任务的成功概率越高, 故最大化该项有助于提高整体任务成功率及复杂任务的执行可靠性。

$\sum_{i=1}^n \sum_{j=1}^m c_{ij} \theta_{ij}$ 函数表示无人机执行全部任务所花费的总飞行时间, 意味着: 数值越小, 代表整体任务完成所需的总飞行时间越短; 优化该项有利于减少总物资投递时间, 帮助受灾人群更快取得物资; 参数 v 用于调控该项成本在整个任务分配策略中的权重, 通过调整 v 可以实现对时间成本与任务收益之间的灵活权衡。

综上所述, 本目标函数在满足约束条件前提下, 最大化无人机对任务执行的信任保障, 同时兼顾任务执行的整体任务时间最短。为了方便后续表述, 将其称为基于信任的目标函数设计 (Trust-Based Objective function, TBOF)。

5.3.3 约束条件

任务分配的具体约束条件如下：

(1) 任务必须且仅被分配给一架无人机执行：

$$\sum_{i=1}^n \theta_{ij} = 1, \quad \forall j \in \{1, 2, \dots, m\} \quad (5.12)$$

(2) 无人机最大任务承载能力为 1：

$$\sum_{j=1}^m \theta_{ij} \leq 1, \quad \forall i \in \{1, 2, \dots, n\} \quad (5.13)$$

(3) 无人机信任值低于任务信任阈值则不予执行：

$$\theta_{ij} = 0, \quad \text{若 } T_{m,i} < T_{j,\min} \quad (5.14)$$

其中 $T_{j,\min}$ 表示任务 j 对无人机综合信任值的最低要求，其值基于公式 (5.8) 和环境复杂度等级对无人机能力的要求计算得到。

(4) 决策变量取值约束：

$$\theta_{ij} \in \{0, 1\}, \quad \forall i, j \quad (5.15)$$

5.4 基于信任的改进遗传算法设计

为了解决无人机任务分配优化问题，本节设计了一种基于信任的改进遗传算法 (Trust-Based Improved Genetic Algorithm, 简称 TIGA)，综合考虑人机信任动态机制以提升任务分配质量。下面将逐一介绍 TIGA 的染色体编码、适应度函数构建、基于信任的锦标赛选择策略、交叉与变异等步骤的设计。

5.4.1 染色体编码

在遗传算法中，每个个体（染色体）代表一种任务分配方案，即每架无人机执行哪些任务。算法采用整数编码方式进行染色体表示：

$$\mathbf{X} = [x_1, x_2, \dots, x_m], \quad x_j \in \{1, 2, \dots, n\} \quad (5.16)$$

其中 x_j 表示第 j 个任务 TG_j 被分配给第 x_j 架无人机。

5.4.2 适应度函数

遗传算法中的适应度函数用于评估个体的优劣，适应度值越高则个体被选入下一代的概率越大。结合基于信任的模型约束设计，适应度函数定义为优化目

标函数 (5.11) :

$$F(X) = \sum_{i=1}^n \sum_{j=1}^m (T_{m,i} w_j \theta_{ij}) - \nu \sum_{i=1}^n \sum_{j=1}^m c_{ij} \theta_{ij} \quad (5.17)$$

其中第一项体现了任务的综合信任收益，第二项则体现总任务完成的时间成本，权衡系数 ν 用于平衡任务收益与执行时间。

5.4.3 基于信任的锦标赛选择

为了解决无人机任务分配问题中存在的信任约束问题，TIGA 算法在传统二元锦标赛选择的基础上引入信任过滤机制。该方法不仅关注个体的适应度，还将无人机信任值作为一个关键指标，确保低信任个体在选择阶段被优先淘汰，从而提高种群的整体能力和算法收敛速度。具体流程如下：

(1) 候选个体的随机抽取：每次从当前种群中随机抽取两个候选个体 X_1 和 X_2 ，其中每个个体表示一种任务分配方案。对于个体 X ，令 x_j 表示分配给任务 TG_j 的无人机编号。

(2) 信任约束检测：对于每个候选个体 X ，定义其信任满足条件：

$$T_{m,x_j} \geq T_{j,\min}, \quad \forall j = 1, 2, \dots, m \quad (5.18)$$

其中 T_{m,x_j} 为无人机 x_j 的信任值， $T_{j,\min}$ 为任务 TG_j 的最低信任要求。若所有条件均成立，则认为该个体满足信任约束，否则认为该个体不满足信任约束。

(3) 候选者比较规则：针对抽取的两个候选个体，采用如下规则进行比较：

- ① 情况一：若 X_1 和 X_2 均满足信任约束，则比较其适应度 $F(X)$ ，选择适应度较高的个体；
- ② 情况二：若只有一个候选个体满足信任约束，则直接选择满足约束的个体；
- ③ 情况三：若两者均不满足信任约束，则计算各自的信任违约程度，定义违约程度为：

$$\Delta(X) = \sum_{j=1}^m \max\{0, T_{j,\min} - T_{m,x_j}\} \quad (5.19)$$

选择违约程度较低的个体进入竞争池。

(4) 重复选择：重复上述二元锦标赛过程，直至选出足够数量的父代个体用于后续的交叉和变异操作。

5.4.4 交叉与变异

遗传算法通常通过交叉和变异操作来生成新个体。交叉操作通过交换父代染色体的部分基因信息产生后代，而变异操作则通过随机改变染色体中的部分

基因来维持种群多样性，并防止算法陷入局部最优。

部分匹配交叉（Partially Matched Crossover, PMX）是一种适用于任务分配问题的交叉方法，其保证了每个个体（染色体）中每个基因仅出现一次，从而避免了基因冲突。PMX 交叉的主要步骤如图5.2所示，首先随机选择两个交叉点确定父代染色体交叉区域的起止位置；其次在该区域内交换两个父代染色体的对应基因得到中间染色体；接着在交叉区域内建立基因的映射关系；最后利用基因映射关系解决交叉区域外因交换产生的基因重复，确保子代染色体中无人机分配的唯一性。




图 5.2 PMX 示意流程图

在遗传算法中，两个被选中的父代个体以交叉概率 p_c 进行交叉，即这两个父代个体有 $1 - p_c$ 的概率直接传递到下一代而不进行交叉。

针对整数编码，本算法采用交换变异方法：在变异过程中，随机选取染色体中的两个基因（即对应于两个任务的无人机分配），并交换这两个基因的位置。变异操作基于预设的变异率 p_m 确定个体是否发生变异。

5.4.5 算法整体流程

TIGA 算法的详细流程如算法5.1所示。

算法 5.1 基于信任优化的改进遗传算法流程

输入: 种群规模 N , 迭代次数 $GEN_{\max}$, 无人机信任值 $T_{m,i}(k-1)$, 任务信任阈值 $T_{j,\min}$, 参数 ν

输出: 最优任务分配方案 X_{best}

```

1 初始化种群  $\{X_1, X_2, \dots, X_N\}$ ;
2 for  $gen \leftarrow 1$  to  $GEN_{\max}$  do
3   计算种群中每个个体  $X_i$  的适应度  $F(X_i)$ ;
4   for  $i \leftarrow 1$  to  $N$  do
5     基于信任的锦标赛选择:
6       随机选取候选个体  $X_1$  和  $X_2$ ;
7       if 两者均满足信任约束 then
8         选择适应度较高的个体
9       else if 仅一个满足约束 then
10        选择满足约束的个体
11      else
12        计算信任违约程度  $\Delta(X)$ 
13        选择违约程度较低的个体
14    将选出的个体存入下一代种群;
15 对下一代种群执行部分匹配交叉 (PMX) 生成新个体;
16 对新种群执行交换变异操作;
17 if  $gen == GEN_{MAX}$  或算法收敛 then
18   跳出循环;
19 输出最优方案  $X_{\text{best}}$ ;
20 更新无人机信任值  $T_{m,i}(k)$ ;

```

5.5 实验与验证

5.5.1 仿真实验设置

本节利用 OpenStreetMap 网站提供的城市地图数据, 构建了 3D 占用地图作为救援仿真区域^[95], 并在 MATLAB 2024a 仿真平台上验证算法的有效性和可行性。该仿真区域对建筑物等飞行障碍物进行立体建模, 从而更直观地展示无人机在物资投递过程中的飞行能力, 并帮助人感知机器的动态能力。实验选取具有实际无人机操控经验的参与者完成实验。

实验采用许万等人提出的基于改进 RRT^* 的路径规划算法^[96], 用于计算无




图 5.3 救援场景 3D 地图

人机与任务目标之间的飞行距离 d ，并应用于任务分配问题求解及无人机飞行路径展示。

在实验过程中，人机系统以 MATLAB 命令行窗口作为数据交互通道，提供双向信息传递机制：(1) 无人机端将机器能力函数值 M_w 、 M_f 、 M_c 及其对应的文本解释信息发送给人类操作者，以确保人能够准确、动态地认知机器能力；(2) 人类操作者在每轮任务分配运行结束后输入更新后的人机信任值，以进一步优化信任模型的参数求解。

在正式任务开始前，通过预实验获取操作者的信任模型参数值，如表 5.1 所示。正式任务采用预实验获取的信任模型值作为无人机能力判断依据，避免实时交互延迟导致的信任更新滞后，为多机任务分配提供动态能力指标。

表 5.1 信任模型参数

参数类别	认知更新因子	值
传感器能力	正向因子 a^{w+}	0.1075
	负向因子 a^{w-}	0.1319
	能力权重 α_w	0.2776
通信能力	正向因子 a^{f+}	0.1361
	负向因子 a^{f-}	0.1539
	能力权重 α_f	0.3753
防碰撞能力	正向因子 a^{c+}	0.1774
	负向因子 a^{c-}	0.1968
	能力权重 α_c	0.3471

5.5.2 实验一：TIGA 方法与基准遗传算法性能对比

5.5.2.1 任务描述

假设在 $600m \times 600m$ 区域内分布着 10 项物资投递任务，无人机系统有 20 架可分配任务的投递无人机，需要从中指派 10 架无人机去分别执行这 10 项任务。表5.2中给出了 20 架无人机的具体信息，表5.3中给出了 10 项任务的具体信息。

表 5.2 无人机信息表

编号	位置	最大速度 (m/s)	信任值 T_i
UAV1	(42, -290)	12	0.83
UAV2	(12, -45)	14	0.66
UAV3	(276, -63)	16	0.92
UAV4	(206, -123)	10	0.75
UAV5	(148, -29)	9	0.89
UAV6	(-234, 215)	11	0.57
UAV7	(-173, 89)	13	0.76
UAV8	(120, 133)	15	0.95
UAV9	(-102, 43)	8	0.64
UAV10	(189, 155)	7	0.98
UAV11	(-256, -109)	17	0.73
UAV12	(63, -173)	6	0.80
UAV13	(100, -200)	12	0.84
UAV14	(-150, 120)	14	0.87
UAV15	(250, 50)	18	0.70
UAV16	(-50, -150)	10	0.79
UAV17	(300, 200)	16	0.91
UAV18	(-300, -50)	9	0.68
UAV19	(0, 0)	11	0.75
UAV20	(80, 220)	8	0.93

实验一从算法收敛速度、总耗时、适应度值三方面对比性能，以采用标准二元锦标赛选择的遗传算法作为基准方法（Base line, BL）与所提 TIGA 方法对比以验证其有效性。实验参数设置如表5.4所示。除所提方法特有的信任阈值参数外，基准方法的参数值与所提方法一致。不同任务复杂度对应的信任阈值 $T_{\min}$ 基于第5.2.2节设计的任务能力阈值和信任公式（5.8）计算得到。共进行 50 次独立实验，以确保实验数据能有效反映两种方法的性能。

表 5.3 任务信息表

任务编号	位置	复杂度等级 w_j
Task1	(-250, 200)	3
Task2	(180, -220)	3
Task3	(270, 150)	3
Task4	(-100, -280)	2
Task5	(300, 100)	2
Task6	(-50, 250)	2
Task7	(100, 100)	1
Task8	(-200, -100)	1
Task9	(0, 250)	1
Task10	(150, -150)	1

表 5.4 算法参数值

参数	值
$w_j = 1$ 对应的信任阈值 $T_{\min}^1$	0.60
$w_j = 2$ 对应的信任阈值 $T_{\min}^2$	0.71
$w_j = 3$ 对应的信任阈值 $T_{\min}^3$	0.86
种群规模 N	100
迭代次数 GEN_{MAX}	100
权衡系数 ν	0.4
交叉概率 p_c	0.8
变异概率 p_m	0.2

两种算法获得的全局最优任务分配方案如表5.5所示，可以看出，两种方法均求得了相同的最优解，充分证明它们在求解精度上均表现优异。图5.4展示了基于该最优方案在 3D 救援场景下的飞行轨迹，表明无人机能够顺利完成物资投递任务。

鉴于两种方法在最优解上一致，为进一步比较两种方法的综合性能，本节将从算法收敛速度、总耗时以及适应度值三个方面对其进行详细分析。

5.5.2.2 算法收敛速度

图5.5展示了在相同参数和实验条件下，两种算法达到收敛所需的最低迭代次数（即收敛速度），其中虚线表示 50 次实验中各算法所需迭代次数的平均值。

表 5.5 实验一：任务分配结果对比

任务编号	TIGA 无人机编号	BL 无人机编号
Task1	UAV14	UAV14
Task2	UAV3	UAV3
Task3	UAV10	UAV10
Task4	UAV1	UAV1
Task5	UAV17	UAV17
Task6	UAV7	UAV7
Task7	UAV8	UAV8
Task8	UAV11	UAV11
Task9	UAV20	UAV20
Task10	UAV13	UAV13




图 5.4 多机任务分配：无人机任务执行轨迹

从图5.5中可以看出，虽然两种算法均存在一定波动性，但所提 TIGA 方法的波动幅度明显小于基准方法 BL，表明 TIGA 在搜索最优任务分配策略时具有更高的收敛稳定性。此外，所提方法的收敛速度曲线整体低于基准方法，且所提 TIGA 方法的收敛速度平均值为 41.0 次，相较于基准方法的 58.2 次有明显的下降。说明在遗传算法选择阶段有选择地剔除低信任个体可以显著提高搜索效率，减少求解所需的时间。




图 5.5 收敛速度对比：TIGA VS BL

5.5.2.3 最优方案总耗时

图5.6展示了两种算法求解出的最优任务分配方案对应的总耗时，其中虚线表示在 50 次实验中各算法所求得最优解总耗时的平均值。从图5.6中可以看出，所提 TIGA 方法的总耗时平均值为 100.6s，略低于基准方法的 107.8s。这说明在遗传算法的选择阶段加入对无人机信任的考量，能够保留更多的接近可行解的个体，有利于提升种群整体性能。




图 5.6 最优任务分配方案的总耗时对比：TIGA VS BL

5.5.2.4 最优方案对应适应度值

图5.7展示了两种算法求解出的最优任务分配方案对应的适应度值，其中虚线表示在 50 次独立实验中各算法最优解适应度的平均值。适应度值体现了算法在满足约束条件前提下对任务优化目标的最大化程度。从图5.7中可以看出，所提 TIGA 方法的适应度平均值为-23.9，略优于基准方法的-26.7，且适应度波动范围也更小。这说明 TIGA 方法通过在选择阶段同时兼顾信任约束和适应度值，提升了算法求解最优方案的稳定性和有效性。




图 5.7 最优任务分配方案的适应度值对比：TIGA VS BL

5.5.3 实验二：基于信任的目标函数设计与传统设计的对比

为深入分析无人机动态能力对任务分配的影响，本实验对比了基于瞬时能力 C_m 和基于综合信任值 T_m 的任务分配方法。具体设计步骤如下：

5.5.3.1 机器能力设计

假设每架无人机在传感器稳定性、通信流畅度和防碰撞能力三个能力类别上的初始值均为其理论能力值 $M_{s,r}$ ，其中传感器稳定性 $M_{s,w} = 0.9$ 、通信流畅度 $M_{s,f} = 0.95$ 及防碰撞能力 $M_{s,c} = 0.95$ 。考虑到实际测量中环境扰动、设备状态变化等因素会导致无人机能力的动态波动，本实验利用 Beta 分布函数在理论能力值基础上叠加随机噪声，仿真生成每轮任务的瞬时能力 C_m 。

通过动态信任模型计算综合信任值 T_m 。该模型不仅考虑了无人机的历史能力变化，还融入了人对无人机长期表现的主观评价，其具体演化过程参考公式 (5.7)。在实验开始前已通过预实验获得了人类操作者的信任模型参数（见

表5.1), 这些参数用于反映人对瞬时能力变化与包含历史表现在内的上一时刻信任的权衡。

5.5.3.2 任务描述

假设在 $600m \times 600m$ 区域内分布着 6 项物资投递任务, 无人机系统有 10 架可分配任务的投递无人机, 需要从中指派 6 架无人机去分别执行这 6 项任务。表5.6 详细记录了十架无人机在前九轮任务中的瞬时能力 C_m 与经过人类操作者评价更新后的综合信任值 T_m 。

表 5.6 无人机动态能力表

编号	参数类别	第一轮	第二轮	第三轮	第四轮	第五轮	第六轮	第七轮	第八轮	第九轮
UAV1	T_m	0.86	0.84	0.84	0.81	0.80	0.80	0.81	0.80	0.81
	C_m	0.75	0.79	0.80	0.70	0.74	0.78	0.87	0.75	0.86
UAV2	T_m	0.89	0.89	0.90	0.87	0.87	0.87	0.87	0.87	0.87
	C_m	0.84	0.90	0.94	0.76	0.87	0.84	0.90	0.87	0.85
UAV3	T_m	0.86	0.85	0.86	0.85	0.84	0.83	0.84	0.85	0.83
	C_m	0.81	0.83	0.86	0.80	0.82	0.80	0.86	0.89	0.76
UAV4	T_m	0.87	0.85	0.83	0.84	0.84	0.84	0.83	0.83	0.84
	C_m	0.79	0.77	0.74	0.84	0.88	0.83	0.79	0.84	0.90
UAV5	T_m	0.85	0.84	0.85	0.84	0.83	0.81	0.82	0.82	0.82
	C_m	0.73	0.82	0.87	0.81	0.79	0.72	0.89	0.84	0.77
UAV6	T_m	0.87	0.84	0.82	0.81	0.81	0.80	0.79	0.78	0.78
	C_m	0.81	0.70	0.77	0.73	0.83	0.73	0.73	0.77	0.79
UAV7	T_m	0.87	0.87	0.86	0.84	0.84	0.84	0.83	0.81	0.81
	C_m	0.82	0.87	0.82	0.74	0.81	0.87	0.79	0.70	0.81
UAV8	T_m	0.88	0.85	0.85	0.86	0.84	0.82	0.80	0.81	0.82
	C_m	0.85	0.75	0.85	0.87	0.75	0.73	0.74	0.85	0.83
UAV9	T_m	0.85	0.86	0.86	0.85	0.84	0.84	0.84	0.82	0.82
	C_m	0.80	0.88	0.84	0.78	0.81	0.86	0.82	0.72	0.84
UAV10	T_m	0.87	0.86	0.86	0.85	0.86	0.84	0.84	0.84	0.83
	C_m	0.81	0.82	0.85	0.77	0.90	0.76	0.87	0.81	0.79

表5.7提供了实验二中无人机的基本信息和前九轮的平均瞬时能力 $\bar{C}_m$ 。表5.8提供了实验二中第十轮任务的信息。

表 5.7 无人机基本信息表

编号	位置 (x, y)	最大速度 (m/s)	平均瞬时能力 $\bar{C}_m$
UAV1	(50, -100)	10	0.78
UAV2	(-200, 150)	8	0.86
UAV3	(0, 0)	9	0.82
UAV4	(100, 250)	11	0.82
UAV5	(-150, -200)	12	0.80
UAV6	(200, -150)	7	0.76
UAV7	(-250, 100)	13	0.80
UAV8	(300, 0)	10	0.80
UAV9	(-50, 300)	9	0.81
UAV10	(150, -250)	11	0.82

表 5.8 第十轮任务信息表

任务编号	位置 (x, y)	复杂度等级 w_j	最低能力要求
Task1	(-250, 200)	3	0.86
Task2	(100, -150)	2	0.71
Task3	(0, 0)	2	0.71
Task4	(200, 150)	2	0.71
Task5	(-100, -100)	2	0.71
Task6	(50, 200)	2	0.71

5.5.3.3 对比方案设计

为客观比较两种方法的效果，基于第九轮数据和第十轮任务信息设计了两组任务分配方案：

(1) 基准方法 (Baseline, BL)：以第九轮瞬时能力 $C_{m,i}(9)$ 为评价指标，通过标准遗传算法计算得到任务分配方案，其适应度函数为：

$$F'(X) = \sum_{i=1}^{10} \sum_{j=1}^6 (C_{m,i}(9)w_j\theta_{ij}) - v \sum_{i=1}^{10} \sum_{j=1}^6 c_{ij}\theta_{ij} \quad (5.20)$$

(2) 基于信任的目标函数设计 (Trust-Based Objective function, TBOF)：以第九轮综合信任值 $T_{m,i}(9)$ 为评价指标，通过本文提出的 TIGA 算法进行任务分配，适

应度函数为：

$$F(X) = \sum_{i=1}^{10} \sum_{j=1}^6 (T_{m,i}(9)w_j\theta_{ij}) - v \sum_{i=1}^{10} \sum_{j=1}^6 c_{ij}\theta_{ij} \quad (5.21)$$

其中 θ_{ij} 代表无人机 i 是否执行任务 j ， c_{ij} 代表无人机 i 完成任务 j 的时间成本， w_j 代表第 j 个任务的环境复杂度等级。

两种方法分别进行 50 次独立实验以获得稳定的最优分配方案，其参数设置均参照表 5.4。

5.5.3.4 实验结果与分析

由于基准方法未考虑信任约束，本节采用无人机在前九轮任务中的平均瞬时能力 $\bar{C}_m$ 作为能力指标，用以判断是否满足任务的最低能力要求。假定当执行任务 j 的无人机能力 $\bar{C}_{m,j} \geq T_{\min}$ 时，视为任务成功完成，任务成功率 L 可通过完成任务数量占总任务数的比值来计算，即：

$$L = \frac{\text{完成任务数}}{\text{总任务数}}$$

为了进一步量化任务分配方案的整体表现，考虑到不同任务具有不同的复杂度等级，且高复杂度任务更需要能力较强的无人机支持，定义任务绩效指标 WR 为：

$$WR = \sum_{j=1}^m \bar{C}_{m,j} w_j \theta_j \quad (5.22)$$

其中 $m = 6$ 表示任务总数， $\bar{C}_{m,j}$ 表示被分配执行任务 j 的无人机的平均瞬时能力， w_j 表示任务 j 的复杂度等级， θ_j 是任务完成标志，若任务完成则取 1，否则取 0。指标 WR 越高，说明整体分配方案中无人机能力与任务复杂度匹配得越好，任务完成的可靠性也更高。

综上，任务成功率 L 用于衡量任务成功完成的概率，而任务绩效 WR 则进一步反映了能力与任务复杂度的匹配情况。两者结合可以更全面地评价任务分配方案的有效性。

实验结果如表 5.9 所示。所提 TBOF 方法的任务成功率 $L = 1$ ，所有任务均顺利完成；而基准方法在 Task1 的分配上存在不足，导致任务成功率仅为 $L = 0.83$ 。这表明 TBOF 方法通过引入综合信任值，能更准确地评估无人机能力，从而提升了任务分配的合理性与任务整体成功率。

基于公式 (5.22) 计算的任务绩效指标显示，TBOF 方法的 $WR = 10.62$ ，显著高于基准方法的 8.02，进一步验证了所提方法在任务完成的可靠性及能力匹配方面具有优势。

表 5.9 实验二：任务分配结果对比

任务编号	BL 方法	是否满足能力要求	TBOF 方法	是否满足能力要求
Task1	UAV4	否	UAV2	是
Task2	UAV1	是	UAV1	是
Task3	UAV3	是	UAV3	是
Task4	UAV8	是	UAV8	是
Task5	UAV5	是	UAV5	是
Task6	UAV9	是	UAV4	是

5.6 本章小结

考虑到无人机能力波动对多机协同救援任务分配的影响，本章提出了基于信任的任务分配方法。通过构建包含传感器稳定性、通信流畅度和防碰撞能力的多维信任模型，实现了对无人机能力的动态评价；基于信任和最短时间约束，构建了兼顾任务成功率与执行效率的优化目标函数；提出了基于信任的锦标赛选择的改进遗传算法 TIGA，提高任务分配求解效率，实现更合理的任务调度。实验结果表明，TIGA 方法在收敛速度、任务总耗时和适应度表现方面均优于传统遗传算法；同时，基于信任的动态任务分配策略相比仅考虑瞬时能力的方法，有效提升了任务成功率。

第6章 总结与展望

6.1 总结

本论文围绕搜救无人机协同控制中的人机信任机制展开研究，针对信任建模、控制权限优化、任务分配优化三个关键问题，提出了针对该场景的信任模型和基于信任的优化方法，以提升无人机在复杂救援环境中的协同能力和任务执行效率。主要贡献包括：

(1) 针对现有信任模型与搜救无人机协同场景的不匹配问题，提出了基于救援无人机能力的人机信任演化模型。考虑到搜救无人机在动态环境中的多维能力表现及人对机器能力的主观认知偏差，论文构建了适用于人与救援无人机协同的信任演化模型，并对模型参数的物理意义和数学性质进行了深入分析，以确保模型的可解释性和合理性。仿真实验结果表明，该模型能够有效跟踪信任值的实时变化，为后续基于信任的控制和任务分配策略提供了可靠的理论支撑。

(2) 针对单机协同搜救任务中仲裁策略难以应对机器高置信度错误和人机认知偏差问题，提出了基于信任的自适应仲裁策略。设计了基于最小化信任偏差的动态透明度策略，通过信任模型预测选取最优透明度水平，使得人机信任处于合理范围，减少因过度信任或低信任导致的不当控制行为。构建了基于信任的自适应仲裁机制，依据信任值动态调整机器控制权边界，并结合碰撞风险优化人机冲突时的权限平滑过渡，以提升系统的协同效率和稳定性。仿真实验结果表明，该方法能够有效减少人类对无人机能力的认知偏差和机器碰撞概率，同时增强人机协作的顺畅性，提升人机系统的协同效能。

(3) 针对多机协同救援任务中无人机能力波动对分配策略的影响，提出了基于信任的任务分配方法。论文将人机信任作为无人机能力的动态评价指标，构建了兼顾任务成功率与执行效率的优化目标函数，确保环境复杂度高的任务由高信任无人机执行，提升任务成功率。此外设计了基于信任的锦标赛选择策略，以提高改进遗传算法的求解效率。仿真实验结果表明，该方法在任务分配效率和任务成功率上均优于传统方法，能够有效提升多无人机协同作业的整体救援性能。

6.2 展望

尽管上述研究取得了一定成果，但仍然存在值得进一步研究的方向：

(1) 优化信任模型的适用性和表达能力。目前的信任模型主要依赖特定的无人机性能指标，未来可以进一步引入环境复杂度、任务风险等级等因素，以增强模型的泛化能力。

(2) 优化单机控制策略,以适应存在通信延迟的场景。现有方法未考虑通信延迟导致的控制权限调整滞后。未来可以研究基于信任的延迟补偿策略,结合预测机制来动态调整控制权限,以确保延迟条件下的人机协作仍然高效可靠。

(3) 提升多机任务分配的适应性和容错能力。在复杂救援任务中,任务执行过程中可能会出现分配失败的情况,未来可以进一步探索基于信任的任务重分配策略,使系统具备更强的任务自适应调整能力。

总的来说,论文的研究为搜救无人机的人机协同提供了一种新的思路,在提升人机协同系统智能化水平和任务执行效率具有重要价值。未来的工作将继续拓展基于信任的优化策略,结合更先进的智能控制和优化算法,并探索更广泛的应用场景,以进一步推动救援无人机协同控制系统的发展。

参考文献

- [1] 李宁, 吴吉东. 自然灾害应急管理导论[M]. 北京: 北京出版社, 2011.
- [2] 范维澄, 陈涛. 国家应急平台体系建设现状与发展趋势[C]//中国突发事件防范与快速处置优秀成果选编. 清华大学公共安全研究中心, 2009: 204-206.
- [3] 郑宇军, 杨潇, 杜怡辰, 等. 人机协同搜救优化问题的计算求解研究[J]. 南昌工程学院学报, 2022, 41(3): 1-11.
- [4] MURPHY S, Robin R. and Tadokoro, NARDI D, JACOFF A, et al. Search and Rescue Robotics[M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008: 1151-1173.
- [5] 袁彪, 刘明鑫. “有人机+无人机”协同模式在气象(衍生)灾害中应急救援策略研究[J]. 农业灾害研究, 2024, 14(8): 323-325.
- [6] 国务院办公厅关于印发国家突发事件应急体系建设“十三五”规划的通知[J]. 中华人民共和国国务院公报, 2017(22): 22-35.
- [7] 国务院关于印发“十四五”国家应急体系规划的通知[J]. 中华人民共和国国务院公报, 2022(6): 30-48.
- [8] LESLIE M. Robots Tackle darpa Underground Challenge[J]. Engineering, 2022, 13: 2-4.
- [9] PAPYAN N, KULHANDJIAN M, KULHANDJIAN H, et al. Ai-based Drone Assisted Human Rescue in Disaster Environments: Challenges and Opportunities[J]. Pattern Recognition and Image Analysis, 2024, 34(1): 169-186.
- [10] 江波, 屈若锟, 李彦冬, 等. 基于深度学习的无人机航拍目标检测研究综述[J]. 航空学报, 2021, 42(4): 137-151.
- [11] 刘森, 姜雪松, 张宇晨, 等. 林火搜救多无人机协同任务分配方法[J]. 中国新技术新产品, 2024(6): 133-136.
- [12] RASHIDA FARSATH K, JITHA K, MOHAMMED MARWAN V, et al. Ai-Enhanced Unmanned Aerial Vehicles for Search and Rescue Operations[C]//2024 5th International Conference on Innovative Trends in Information Technology. 2024: 1-10.
- [13] LUO Y, YU H, ZHANG H, et al. A Novel Newton-Euler Method-Based Nonlinear Anti-Swing Control for a Quadrotor UAV Carrying a Slung Load[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2024, 54(4): 2266-2275.
- [14] HE B, JI X, LI G, et al. Key Technologies and Applications of UAVs in Underground Space: A Review[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(3): 1026-1049.
- [15] YAMPOLSKIY R V. Unexplainability and Incomprehensibility of AI[J]. Journal of Artificial Intelligence and Consciousness, 2020, 07(2): 277-291.

- [16] YAMPOLSKIY R V. Ai: Unexplainable, Unpredictable, Uncontrollable[M]. CRC Press, 2024.
- [17] WANNER D, HASHIM H A, SRIVASTAVA S, et al. Uav Avionics Safety, Certification, Accidents, Redundancy, Integrity, and Reliability: a Comprehensive Review and Future Trends [J]. Drone Systems and Applications, 2024, 12: 1-23.
- [18] JOHNSON J. Automating the OODA Loop in the Age of Intelligent Machines: Reaffirming the Role of Humans in Command-and-Control Decision-Making in the Digital Age[J]. Defence Studies, 2023, 23(1): 43-67.
- [19] TAO Y, QIU J, LAI S, et al. A Human-Machine Reinforcement Learning Method for Cooperative Energy Management[J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 2974-2985.
- [20] LIU L, WANG X, YANG X, et al. Path Planning Techniques for Mobile Robots: Review and Prospect[J]. Expert Systems with Applications, 2023, 227: 120254.
- [21] HARI S K K, SUNDAR K, RATHINAM S, et al. Scheduling Tasks for Human Operators in Monitoring and Surveillance Applications[J]. IFAC-PapersOnLine, 2016, 49(32): 54-59.
- [22] 赵云波, 康宇, 朱进. 人机混合智能系统自主性理论和方法[M]. 科学出版社, 2021.
- [23] MORROW J, ZAWODNIOK M, MOHAMMED A S. Impact of AI on the HRI Dynamic in Search and Rescue Operations using UAV Swarms[C]//2024 IEEE International Symposium on Robotic and Sensors Environments. 2024: 01-08.
- [24] LYU M, ZHAO Y, HUANG C, et al. Unmanned Aerial Vehicles for Search and Rescue: A Survey[J]. Remote Sensing, 2023, 15(13).
- [25] ISAACS J T, KNOEDLER K, HERDERING A, et al. Teleoperation for Urban Search and Rescue Applications[J]. Field Robotics, 2022, 2: 1177-1190.
- [26] THOMASON J, RATSAMEE P, ORLOSKY J, et al. A Comparison of Adaptive View Techniques for Exploratory 3D Drone Teleoperation[J]. ACM Transactions on Interactive Intelligent Systems, 2019, 9(2-3).
- [27] RUIYU X, YUNBO Z, JUNSEN L, et al. Trust-Modulated Authority Allocation in Human-Guided Goal Recognition Tasks[C]//Proceedings of the 2nd International Conference. Amsterdam: IOS Press, 2025: 516-522.
- [28] MGHABGHAB S, ELHAJJ I H, ASMAR D. Personalized Teleoperation via Intention Recognition[J]. Advanced Robotics, 2018, 32(13): 697-716.
- [29] WANG Q, HE B, XUN Z, et al. Gpa-Teleoperation: Gaze Enhanced Perception-Aware Safe Assistive Aerial Teleoperation[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 5631-5638.
- [30] HOU X. Haptic Teleoperation of a Multirotor Aerial Robot using Path Planning with Human

- Intention Estimation[J]. Intelligent Service Robotics, 2021, 14(1): 33-46.
- [31] CHEN S K, CHEN C S. Motion Primitive Recognition on Human Guided Robotic Arm using Machine Learning[C]//2019 19th International Conference on Control, Automation and Systems. 2019: 955-960.
- [32] TANWANI A K, CALINON S. A Generative Model for Intention Recognition and Manipulation Assistance in Teleoperation[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems. 2017: 43-50.
- [33] SCHULTZ C, GAURAV S, MONFORT M, et al. Goal-Predictive Robotic Teleoperation from Noisy Sensors[C]//2017 IEEE International Conference on Robotics and Automation. 2017: 5377-5383.
- [34] PENG Q, WU H, XUE R. Review of Dynamic Task Allocation Methods for UAV Swarms Oriented to Ground Targets[J]. Complex System Modeling and Simulation, 2021, 1(3): 163-175.
- [35] ALLABAN A A, DIMITROV V, PADIR T. A Blended Human-Robot Shared Control Framework to Handle Drift and Latency[C]//2019 IEEE International Symposium on Safety, Security, and Rescue Robotics. Würzburg, Germany: IEEE, 2019: 81-87.
- [36] ZHOU L, DOU Y, LIU H, et al. Shared Control Method for Coal Mine Rescue Robots[C]//2021 5th CAA International Conference on Vehicular Control and Intelligence (CVCI). 2021: 1-6.
- [37] LUO J, LIN Z, LI Y, et al. A Teleoperation Framework for Mobile Robots Based on Shared Control[J]. IEEE Robotics and Automation Letters, 2020, 5(2): 377-384.
- [38] LI Y, CUI R, YAN W, et al. Reconciling Conflicting Intent: Bidirectional Trust-Based Variable Autonomy for Mobile Robots[J]. IEEE Robotics and Automation Letters, 2024, 9(6): 5615-5622.
- [39] 毕文豪, 张梦琦, 高飞, 等. 无人机集群任务分配技术研究综述[J]. 系统工程与电子技术, 2024, 46(3): 922-934.
- [40] 沈林成, 牛轶峰, 朱华勇. 多无人机自主协同控制理论与方法[M]. 国防工业出版社, 2018.
- [41] MICHALEWICZ Z. Genetic Algorithms + Data Structures = Evolution Programs[M]. Springer Science & Business Media, 2013.
- [42] KATOCH S, CHAUHAN S S, KUMAR V. A Review on Genetic Algorithm: Past, Present, and Future[J]. Multimedia Tools and Applications, 2020, 80: 8091 - 8126.
- [43] KENNEDY J, EBERHART R. Particle Swarm Optimization[C]//Proceedings of ICNN'95 - International Conference on Neural Networks: Vol. 4. 1995: 1942-1948 vol.4.
- [44] 邸斌, 周锐, 丁全心. 多无人机分布式协同异构任务分配[J]. 控制与决策, 2013, 28(2): 274-278.

- [45] GAO C, ZHEN Z, GONG H. A Self-Organized Search and Attack Algorithm for Multiple Unmanned Aerial Vehicles[J]. Aerospace Science and Technology, 2016, 54: 229-240.
- [46] ZHEN Z, XING D, GAO C. Cooperative Search-Attack Mission Planning for Multi-UAV Based on Intelligent Self-Organized Algorithm[J]. Aerospace Science and Technology, 2018, 76: 402-411.
- [47] BRUTSCHY A, PINI G, PINCIROLI C, et al. Self-Organized Task Allocation To Sequentially Interdependent Tasks in Swarm Robotics[J]. Autonomous agents and multi-agent systems, 2014, 28: 101-125.
- [48] HONG A, IGHARORO O, LIU Y, et al. Investigating Human-Robot Teams for Learning-Based Semi-autonomous Control in Urban Search and Rescue Environments[J]. Journal of Intelligent & Robotic Systems, 2019, 94(3-4): 669-686.
- [49] LEE J D, SEE K A. Trust in Automation: Designing for Appropriate Reliance[J]. Human Factors: The Journal of the Human Factors and Ergonomics Society, 2004, 46(1): 50-80.
- [50] HOFF K A, BASHIR M. Trust in Automation: Integrating Empirical Evidence on Factors That Influence Trust[J]. Human Factors, 2015, 57(3): 407-434.
- [51] AKASH K, MCMAHON G, REID T, et al. Human Trust-Based Feedback Control: Dynamically Varying Automation Transparency to Optimize Human-Machine Interactions[J]. IEEE Control Systems, 2020, 40(6): 98-116.
- [52] WANG Q, LIU D, CARMICHAEL M G, et al. Computational Model of Robot Trust in Human Co-Worker for Physical Human-Robot Collaboration[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 3146-3153.
- [53] HANCOCK P A, BILLINGS D R, SCHAEFER K E, et al. A Meta-Analysis of Factors Affecting Trust in Human-Robot Interaction[J]. Human Factors: The Journal of the Human Factors and Ergonomics Society, 2011, 53(5): 517-527.
- [54] HU W L, AKASH K, REID T, et al. Computational Modeling of the Dynamics of Human Trust During Human - Machine Interactions[J]. IEEE Transactions on Human-Machine Systems, 2019, 49(6): 485-497.
- [55] PAN J, EDEN J, OETOMO D, et al. Effects of Shared Control on Cognitive Load and Trust in Teleoperated Trajectory Tracking[J]. IEEE Robotics and Automation Letters, 2024, 9(6): 5863-5870.
- [56] FLOYD M W, DRINKWATER M, AHA D W. Trust-Guided Behavior Adaptation using Case-Based Reasoning[C]//IJCAI'15: Proceedings of the 24th International Conference on Artificial Intelligence. Buenos Aires, Argentina: AAAI Press, 2015: 4261-4267.
- [57] LEE J, MORAY N. Trust, Control Strategies and Allocation of Function in Human-Machine Systems[J]. Ergonomics, 1992, 35(10): 1243-1270.

- [58] XU A, DUDEK G. OPTIMo: Online Probabilistic Trust Inference Model for Asymmetric Human-Robot Collaborations[C]//Proceedings of the Tenth Annual ACM/IEEE International Conference on Human-Robot Interaction. Portland Oregon USA: ACM, 2015: 221-228.
- [59] CHEN J Y, PROCCI K, BOYCE M, et al. Situation Awareness-Based Agent Transparency[J]. US Army Research Laboratory, 2014(4): 1-29.
- [60] HUANG S H, BHATIA K, ABBEEL P, et al. Establishing Appropriate Trust via Critical States [C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid: IEEE, 2018: 3929-3936.
- [61] NIU D, TERKEN J, EGGEN B. Anthropomorphizing Information to Enhance Trust in Autonomous Vehicles[J]. Human Factors and Ergonomics in Manufacturing & Service Industries, 2018, 28(6): 352-359.
- [62] REZVANI T, DRIGGS-CAMPBELL K, SADIGH D, et al. Towards Trustworthy Automation: User Interfaces That Convey Internal and External Awareness[C]//2016 IEEE 19th International Conference on Intelligent Transportation Systems. Rio de Janeiro, Brazil: IEEE, 2016: 682-688.
- [63] OKAMURA K, YAMADA S. Empirical Evaluations of Framework for Adaptive Trust Calibration in Human-AI Cooperation[J]. IEEE Access, 2020, 8: 220335-220351.
- [64] OKAMURA K, YAMADA S. Adaptive Trust Calibration for Human-AI Collaboration[J]. PLOS ONE, 2020, 15(2): e0229132.
- [65] WANG Q, LIU D, CARMICHAEL M G, et al. Robot Trust and Self-Confidence Based Role Arbitration Method for Physical Human-Robot Collaboration[C]//2023 IEEE International Conference on Robotics and Automation. London, United Kingdom: IEEE, 2023: 9896-9902.
- [66] ZAHEDI Z, VERMA M, SREEDHARAN S, et al. Trust-Aware Planning: Modeling Trust Evolution in Iterated Human-Robot Interaction[C]//Proceedings of the 2023 ACM/IEEE International Conference on Human-Robot Interaction. Stockholm Sweden: ACM, 2023: 281-289.
- [67] GUO Y, PANG Y, LYONS J, et al. Trust-Aware Reflective Control for Fault-Resilient Dynamic Task Response in Human-Swarm Cooperation[J]. AI, 2024, 5(1): 446-464.
- [68] HOFFMAN G, BHATTACHARJEE T, NIKOLAIDIS S. Inferring Human Intent and Predicting Human Action in Human-Robot Collaboration[J]. Annual Review of Control, Robotics, and Autonomous Systems, 2024, 7(1): 73-95.
- [69] YU Y, SI X, HU C, et al. A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures[J]. Neural computation, 2019, 31(7): 1235-1270.
- [70] GIULIARI F, HASAN I, CRISTANI M, et al. Transformer Networks for Trajectory Forecasting[C]//2020 25th international conference on pattern recognition. IEEE, 2021: 10335-10342.
- [71] JAIN S, ARGALL B. Recursive Bayesian Human Intent Recognition in Shared-Control

- Robotics[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid: IEEE, 2018: 3905-3912.
- [72] 刘振, 李伟, 任建存. 多基地多 UCAV 任务分配建模及求解方法[J]. 东南大学学报 (自然科学版), 2019, 49(1): 88-93.
- [73] WANG Z, LIU L, LONG T, et al. Multi-UAV Reconnaissance Task Allocation for Heterogeneous Targets Using an Opposition-Based Genetic Algorithm with Double-Chromosome Encoding[J]. Chinese Journal of Aeronautics, 2018, 31(2): 339-350.
- [74] JIA Z, YU J, AI X, et al. Cooperative Multiple Task Assignment Problem with Stochastic Velocities and Time Windows for Heterogeneous Unmanned Aerial Vehicles Using a Genetic Algorithm[J]. Aerospace Science and Technology, 2018, 76: 112-125.
- [75] 薛文涛, 王强, 吴晓蓓. 基于特异性免疫策略的遗传算法及应用[J]. 系统仿真学报, 2008 (16): 4315-4322.
- [76] COLLEY M, SPEIDEL O, STROHBECK J, et al. Effects of Uncertain Trajectory Prediction Visualization in Highly Automated Vehicles on Trust, Situation Awareness, and Cognitive Load[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2023, 7(4): 1-23.
- [77] AZEVEDO-SA H, JAYARAMAN S K, ESTERWOOD C T, et al. Real-Time Estimation of Drivers' Trust in Automated Driving Systems[J]. International Journal of Social Robotics, 2021, 13(8): 1911-1927.
- [78] AZEVEDO-SA H, JAYARAMAN S K, YANG X J, et al. Context-Adaptive Management of Drivers' trust in Automated Vehicles[J]. IEEE Robotics and Automation Letters, 2020, 5(4): 6908-6915.
- [79] TOWERS M, KWIATKOWSKI A, TERRY J, et al. Gymnasium: A Standard Interface for Reinforcement Learning Environments[EB]. 2024-07-17[2025-03-26]. <https://arxiv.org/abs/2407.17032>.
- [80] HASSELT H V, GUEZ A, SILVER D. Deep Reinforcement Learning with Double Q-Learning [C]//AAAI'16: Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, Arizona: AAAI Press, 2016: 2094-2100.
- [81] JAIN S, ARGALL B. Recursive Bayesian Human Intent Recognition in Shared-Control Robotics[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. 2018: 3905-3912.
- [82] SONG P, LI P, AERTBELIËN E, et al. Robot Trajectron: Trajectory Prediction-Based Shared Control for Robot Manipulation[C]//2024 IEEE International Conference on Robotics and Automation. 2024: 5585-5591.
- [83] MUELLING K, VENKATRAMAN A, VALOIS J S, et al. Autonomy Infused Teleopera-

- tion with Application to Brain Computer Interface Controlled Manipulation[J]. *Autonomous Robots*, 2017, 41(6): 1401-1422.
- [84] JESSIE C, SHAN L, KIMBERLY S, et al. Situation Awareness-Based Agent Transparency and Human-Autonomy Teaming Effectiveness[J]. *Theoretical Issues in Ergonomics Science*, 2018, 19(3): 259-282.
- [85] AKASH K, JAIN N, MISU T. Toward Adaptive Trust Calibration for Level 2 Driving Automation[C]//*Proceedings of the 2020 International Conference on Multimodal Interaction*. 2020: 538-547.
- [86] ROESLER E, MANZEY D, ONNASCH L. A Meta-Analysis on the Effectiveness of Anthropomorphism in Human-Robot Interaction[J]. *Science Robotics*, 2021, 6(58): eabj5425.
- [87] ROESLER E, VOLLMANN M, MANZEY D, et al. The Dynamics of Human-Robot Trust Attitude and Behavior —Exploring the Effects of Anthropomorphism and Type of Failure[J]. *Computers in Human Behavior*, 2024, 150: 108008.
- [88] JAVDANI S, ADMONI H, PELLEGRINELLI S, et al. Shared Autonomy via Hindsight Optimization for Teleoperation and Teaming[J]. *Int J Rob Res*, 2018, 37(7): 717-742.
- [89] 何舟, 何鹏阳. 考虑故障因素的多机器人动态任务分配及路径规划[J]. *计算机应用研究*, 2025, 42(6): 1-8.
- [90] 张硕, 陆宇峰, 王丹翔, 等. 基于 YOLOv4-tiny 的无人机全自动跟踪方法[J]. *兵器装备工程学报*, 2023, 44(09): 34-41.
- [91] CHEN J, YU C, XIE Y, et al. What Matters in Learning a Zero-Shot Sim-to-Real RL Policy for Quadrotor Control? A Comprehensive Study[EB]. 2024-11-23[2025-03-26]. <https://api.semanticscholar.org/CorpusID:274776741>.
- [92] HARUN M, ABDULLAH S, ARAS M, et al. Recent Developments and Future Prospects in Collision Avoidance Control for Unmanned Aerial Vehicles (UAVS): A Review[J]. *International Journal of Robotics and Control Systems*, 2024, 4(3): 1207-1242.
- [93] SAADOU A, CHENJI H. Optimizing Situational Awareness in Disaster Response Networks [J]. *IEEE Access*, 2018, 6: 24625-24638.
- [94] GUO K, ZHANG W, ZHU Y, et al. Safety Control for Quadrotor UAV Against Ground Effect and Blade Damage[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(12): 13373-13383.
- [95] OpenStreetMap contributors. Openstreetmap: A Free Wiki World Map[DB]. [2025-03-26]. <https://www.openstreetmap.org>.
- [96] 许万, 杨晔, 余磊涛, 等. 一种基于改进 RRT* 的全局路径规划算法[J]. *控制与决策*, 2022, 37(4): 829-838.

致谢

时光荏苒，白驹过隙。三年的研究生时光，如一场季节的轮回，悄然走入尾声。此刻提笔，满怀感激与眷恋，心中百感交集，言语难尽。回首在科大的日日夜夜，感谢的人与事如繁星点点，铭记于心。

感谢我的导师康宇教授和赵云波教授。学生愚钝，幸得两位老师的耐心教导与不懈鼓励，才得以一步步走到今天。感谢康老师愿意接纳我成为您的学生，提供优越的科研平台。在科研和生活中，您始终给予我悉心指导与关怀支持，使我不断进步。感谢赵老师在科研思维上的细致培养，帮助我逐步建立起严谨的学术逻辑，学会如何分析问题、系统解决问题。两位老师扎实的学术功底与严谨的治学态度，将是我一生学习的榜样。

感谢我的实践导师许镇义，您在项目上的专业精神与高效执行力让我十分敬佩。您的认真负责和务实态度，对我今后的学习和工作都有着重要的指导意义。

感谢学院的各位老师，感谢你们在课程学习上的悉心指导，在日常事务中的耐心关怀，在学术评审中的专业点评。你们的教诲如春雨般润物无声，让我在知识的沃土上汲取养分，茁壮成长；你们的鼓励与支持，给予我坚定前行的信心。

感谢实验室的各位师兄师姐，刚进实验室时，我也曾迷茫和惶恐。是你们用包容和关爱构建了一个团结互助的集体，让我很快找到了归属感。感谢师兄师姐们在科研和生活中给予我支持和鼓励，让我受益良多，希望大家科研和工作顺利，成果越攒越多。

感谢并肩作战的同门，回忆起第一次来科大，一起去大蜀山的时光还历历在目。我们一起科研、讨论问题，也在学习之余一起散步、相互鼓励。你们的陪伴让这段时光变得格外温暖。很感激能够与你们相遇在科大，也希望未来能在顶峰相见。感谢我的挚友张可和邹岷强，我们互相鼓励、互相学习、互相分享快乐，你们是我的快乐源泉，也是我保持乐观的动力。希望我们的未来都能繁花似锦。

感谢我的家人对我无条件的支持与理解。是你们始终如一的信任和爱，让我在前行的路上无所畏惧；是你们给予了我无微不至的照顾，托举起了我，让我不必担心不必焦虑。

研究生生活即将画上句点，但这里的记忆与感动将永远留在我心中。谨以此致谢，献给这段难忘的青春岁月，献给所有曾经给予我帮助与鼓励的人。

在读期间取得的科研成果

会议论文:

- (1) Yun-Bo Zhao, Zuhao Xie, Chang Xu, Xiuhua Liang, **Ruiyu Xia**, and Jiayu Li. A Novel Haptic Takeover Method Based on Human-Machine Collaboration States, The 14th Asian Control Conference, 2024,06.
- (2) **Ruiyu Xia**, Yun-Bo Zhao, Junsen Lu, Yang Wang, Pengfei Li and Yu Kang. Trust-Modulated Authority Allocation in Human-Guided Goal Recognition Tasks, The 2nd International Conference on Artificial Intelligence and Human-Computer Interaction, 2024,10.

已投稿论文:

- (1) Yun-Bo Zhao, Junsen Lu, Yang Wang, Shaojun Chen, **Ruiyu Xia**, Pengfei Li, Yu Kang. A Machine-Performance-Driven Human Trust Model for AI-Powered Human-Machine Systems. IEEE Transactions on Human Machine Systems, 在投.

软件著作权:

- (1) 康宇, 田霞, 董凯, 鲁理, **夏睿钰**, 赵云波, 刘斌琨, 李晓蒙. 眼科病人信息录入软件 V1.0. 登记号: 2023SR1536691, 2023-11-30.