



汕 頭 大 學

SHANTOU UNIVERSITY

硕 士 学 位 论 文

题 目：基于三维基因调控网络的群体智能机器人研究

英文题目：Research on Swarm Intelligent Robots Based on
Three-Dimensional Gene Regulation Network

姓 名马培立 学 号151909089

所在学院工学院 导师姓名范 衡

专 业电子与通信工程

入学日期2019 年 9 月 答辩日期2022 年 5 月

学位论文原创性声明

本论文是我个人在导师指导下进行的工作研究及取得的研究成果。论文中除了特别加以标注和致谢的地方外，不包含其他人或其他机构已经发表或撰写过的研究成果。对本文的研究做出贡献的个人和集体，均已在论文中以明确方式标明。本人完全意识到本声明的法律责任由本人承担。

作者签名：_____ 日期：_____年____月____日

学位论文使用授权声明

本人授权汕头大学保存本学位论文的电子和纸质文档，允许论文被查阅和借阅；学校可将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或其他复制手段保存和汇编论文；学校可以向国家有关部门或机构送交论文并授权其保存、借阅或上网公布本学位论文的全部或部分内容。对于保密的论文，按照保密的有关规定和程序处理。

作者签名：_____ 导师签名：_____

日期：_____年____月____日 日期：_____年____月____日



汕 頭 大 學
SHANTOU UNIVERSITY

硕 士 学 位 论 文

论文中文题目：基于三维基因调控网络的群体智能机器人研究

论文英文题名：Research on Swarm Intelligent Robots Based on Three-
Dimensional Gene Regulation Network

指 导 教 师：范衡

申 请 人：马培立

论文答辩委员会成员

主席：肖刚 教授 韩山师范学院

委员：陈耀文 教授 汕头大学工学院电子系

邹安民 教授 汕头大学工学院电子系

赖李洋 教授 汕头大学工学院电子系

李兵 教授 汕头大学工学院电子系

摘要

近年来,针对群体机器人的研究开始被广泛应用于仿生学、人工智能、物流配送、协同探索、军事打击等领域。群体智能机器人这一研究始于对自然界中的飞禽、走兽、游鱼、细胞等群体形态的研究。由于这些群体的感知、决策和行动均是有限的,难以做出复杂的行为操作。但是这些生物的群体行为可以通过遵循简单的行为规则,在群体层面上相互协作,完成迁徙、御敌、觅食、筑巢等复杂行为。对群体机器人而言,学习这种生物集群的智能涌现行为,可以有效地提高群体机器人在面临真实环境场景下的集群决策、高效协调、自主决策的能力。为此本文提出了一种在三维空间适用的三维基因调控网络,并在无人机集群的模拟仿真中进行了讨论和研究。具体如下:

1. 针对三维空间中目标跟踪和围捕问题,本文从细胞集群的基因表达出发,提出了一种基于三维基因调控网络的群体聚合形态主动生成的方法。该方法通过模型库遗传迭代的方法,根据环境的特征和目标的影响力自动生成出一套符合这类场景的具体解决模型,并在此基础上进一步裁剪获得一套简单且通用的群体聚合网络。通过从包围距离、包围圈浓度、围捕强度三个方面来证实,我们选择的简易的基因模型具有良好的鲁棒性。

2. 针对如何将三维空间中分布式自主策略控制设计应用到无人机集群自主控制的问题,本文进一步提出了在局部坐标系下三维基因调控网络的群体聚合形态生成的框架。该框架抛弃了传统基因调控网络认为所有栅格均同等重要的原则,并简化了控制模型,让该算法能够完全脱离计算中心,并嵌入到无人机自身的系统上。从而保证了无人机集群能够快速的响应并围捕动态目标,并在受到打击后能够恢复包围圈进行围捕。通过仿真实验以及三维全局基因调控网络对比来看,该方法能在保证运算效率的前提下仍然能够适应动态环境,并拥有较好的鲁棒性以适应困难的场景。

关键词: 群体智能机器人; 基因调控网络; 三维空间; 群体聚合形态; 分布式围捕; 无人机集群

Abstract

In recent years, swarm robots have been widely applied in the fields of bionics, artificial intelligence, logistics, cooperative exploration, military attack, and so on. The research of swarm intelligent robotics started from the study of the group morphology of bird, beast, fish, and cell in nature. Due to the limited perception, decision-making and action abilities of individuals in these groups, it is difficult to make complex behavioral operations. However, these groups can perform complex behaviors, such as migration, fighting enemies, foraging, and nesting by following simple behavioral rules and cooperating with each other at the group level. The intelligent emergent behavior of biological cluster can improve the intelligent decision-making, efficient coordination, and autonomous decision-making ability of swarm robots in complex environments. To this end, a three-dimensional gene regulation network applicable in three-dimensional space is proposed in this thesis, which is also discussed and studied in the simulation of UAV clusters. The details are as follows:

1. To address the problem of target tracking and trapping in three-dimensional space, this thesis proposes a method for actively generating population aggregation morphology based on a three-dimensional gene regulatory network, starting from the gene expression of cell clusters. Based on the environment characteristics and the influence of the target, the method can automatically generate a set of specific solution models that meet current scenarios through the genetic iteration of the model library, and further tailor to obtain a simple and general set of population aggregation networks. Finally, the robustness of our model is verified from three aspects: enclosure distance, enclosure concentration, and enclosure intensity.

2. Aiming at the problem of distributed autonomous control of UAV cluster in three-dimensional space, this thesis further proposes a framework for automatic generation of population aggregation morphology of 3D gene regulatory network in local coordinate system. This framework abandons the principle that all grids are equally important in traditional gene regulatory networks, and simplifies the control model so that the algorithm can be embedded in UAV cluster systems, which ensures that the UAV clusters can quickly tracking the dynamic target, and after being attacked can generate a suitable encircle. Simulation results show that the proposed method is robust and adaptive to dynamic

environment under the premise of ensuring computational efficiency.

Keywords: Swarm intelligent robot; Gene regulation network; Three-dimensional space; Population aggregation morphology; Distributed rounding up; Drone cluster.

目 录

摘要	I
Abstract	II
目 录	IV
第 1 章 绪论	6
1.1 课题研究背景与意义	6
1.2 群体机器人发展简述	8
1.3 典型生物群体行为模型及特点	10
1.3.1 蚁群优化控制模型	10
1.3.2 鸽群机制编队模型	11
1.3.3 细胞基因调控模型	12
1.3.4 群体智能行为特点	13
1.4 主要研究内容及结构安排	14
第 2 章 从生物群体行为到机器人群体模型的国内外研究现状	15
2.1 群体机器人编队控制	15
2.2 群体机器人围捕控制	15
2.3 本章小结	16
第 3 章 三维空间下群体聚合形态自动生成框架	17
3.1 基因调控网络简介	17
3.2 自定义元件库及使用	18
3.2.1 基因调控网络的基本元件库	19
3.2.2 基因调控网络适应度函数定义	22
3.3 基于三维基因调控网络的群体模式生成方法	23
3.3.1 基于全局信息的三维聚合形态自适应生成	23
3.3.2 群体机器人群体聚合形态的控制与形成	26

3.3.3 群体机器人评价指标与效能	27
3.3.4 实验与分析	29
3.4 本章小结	32
第 4 章 三维局部分布式基因调控网络模型	34
4.1 模型描述及关键技术	34
4.1.1 整体模型框架	35
4.1.2 三维空间中局部坐标系建立	36
4.1.3 三维空间中运动控制策略	41
4.2 实验研究	43
4.2.1 三维局部基因调控网络结果分析	43
4.2.2 三维局部基因调控网络与全局基因调控网络的差异	46
4.3 本章小结	47
第 5 章 总结与展望	49
5.1 本文小结	49
5.2 未来展望	50
参考文献	51
攻读硕士学位期间主要的工作成果	56
致谢	58

第1章 绪论

集群概念最早源于生物学领域当中，法国动物学家 Pierre-Paul Grassé 根据大自然中蚁群筑巢的行为，在生物界中首次提出了共识主动性（Stigmergy）这一概念。其认为共识主动性是一种集群中个体与个体间的间接协调的机制，无需通过中心控制，只需要通过个体与个体间的信息交互即能完成单个个体无法完成的复杂活动。作为一种自驱动演化系统，共识集群的概念也已然从生物集群扩展到机器人集群。随着近年来群体机器人研究的不断深入，人们希望集群内的群体机器人拥有足够的自驱性，这就要求集群内的机器人可以通过低数据量的信息传输与简单的运动学控制模型突显出复杂的行为任务，以具备机器人之间的共识主动性。具体来说，机器人群体的群体运动任务就是大量具有单一功能的简单机器人按照一定的策略来完成在空间中跟随、围捕的任务。

实际上，在生物体中存在着大量的群体涌现。蜂群、鸽群、雁群、狼群、菌群等生物群体可以通过个体自主决策和简单的信息交互表现出分布、协调、围捕、稳定等复杂状态，并最终使整个群体宏观上涌现出自组织性，协作性^[1]。由于生物集群之间存在有去中心化、临近个体交互、整体有目的组织性等特点，因此通过模拟这些生物的智能行为，能够将仅具有局部感知能力的简单个体聚成复杂的机器人集群系统。

随着学者对群体任务的深入研究，各类基于生物群体的人工群体系统被一一提出。目前主流的研究方向包含群体编队^[2]以及群体围捕^[3]两大领域，相较于群体编队而言，群体围捕往往需要考虑到围捕机器人之间的相互制约。因此群体围捕往往会伴随着更大的计算量以及更复杂的群体涌现研究，所以该方向一直以来是研究的热点问题。为此我们从生物集群行为出发，研究无人机集群在三维空间下的自适应框架的生成与评估。

1.1 课题研究背景与意义

日益复杂的任务与环境决定了群体机器人系统必须具有很高的自主型，以无人机为代表的群体机器人要求该系统具有较高的自治能力^[4-5]，以保证在陌生的环境条件下，能够持续完成必要的群体控制，并形成良好的群体涌现机制。

以美国国防高级研究计划局(Defense Advanced Research Projects Agency, DARPA),

海军研究局为代表的组织机构，在无人机集群设计与验证方面成果显著。2005 年 8 月，美国国防部发表的《无人机系统路线图 2005-2030》^[6]即指出无人机分为十个等级，主要分为单机自主、多机自主、群体自主这三个层面。其中指出“全自主集群”是无人机自主控制的最高等级^[7]，相比于多机自主中的“多机协调”级别而言，“全自主集群”不但要求无人机的规模无明显限制而且需要无人机拥有良好的自主能力。如图 1-1 所示，2016 年 5 月，美国空军发布了《小型无人机系统飞行规划 2016-2036》^[8]，并从战略层面上肯定了小型无人机集群在战场的应用前景与价值，规划中对三种作战理念进行了详细阐述分别是“编组”、“忠诚僚机”以及“蜂群”。分别对应着人对人、人对机以及机对机。在发展规划中将无人机全自主集群作为未来发展的三个主要规划之一，这也从技术层面上指明了无人机集群未来的发展方向。在 2018 年 8 月，美国国防部又发布了《无人系统综合路线图 2017-2042》^[9]，并进一步从无人机集群整体的层面上指出了无人机集群在无人集群系统领域的重要分量。




图 1-1 小型无人机系统飞行规划(2016-2036)

随着机器人集群个体自主化程度不断提高，如何设计开发出一套具有适用性的无人机集群系统已然成为无人集群领域的一个重要方向。学术界一致认为，在未来通过集群之间的紧密合作，集群无人机可以带来单一无人机无法体现的巨大优势。相比于人工系统，无人机集群系统还具有以下特点：可有效通过无人机之间的协调来避免机器与机器之间的冲突；可以大幅度降低单个无人机的成本，并利用集群无人机来弥补单一无人机的不足；在受到打击后，无人机集群因其可以去中心化，从而从根本上避

免了中心受到打击导致的整个集群系统的瘫痪；网络之间可以高速局部信息共享，并能在收到打击后拥有一定的自愈性；集群中的每个个体都可以拥有一定程度的决策权，通过投票的方式来解决复杂的决策问题，这种策略往往可以根据当前情况实时做出合理的假设，比人工设计模型正确率更高。

综上所述，无人机集群拥有着单个无人机无法媲美的优势。无人机集群根据任务能够自行对任务进行分配，且每一个无人机均具有部分自主能力。这在大大降低操作人员工作的同时，能够统一调度，协同完成复杂任务。无人机集群相较于传统的无人机更加适用于复杂的任务场景，传统的单一无人机系统会存在大量的硬件冗余，系统会存在主从分别，动态调节能力有限，当出现传感器故障时有可能导致整个系统功能失效等问题。无人机集群可以通过集群控制的方法来保证复杂场景中机器人系统具备硬件低冗余性、无中心性、系统高动态调节性，同时集群机器人传感器之间可以相互补充自身缺少的信息来保证无人机集群能够根据不同的环境自适应改变自身的形态。

无人机集群按照应用模式来分，其大致分为：渗透侦查、诱骗干扰、侦查击打一体、协同攻击这四种应用模式。协同攻击作为四种应用中最能体现协同作战的应用，这就需要无人机集群能够完成跟踪到围捕的形态变化，从而能够让围捕无人机从各个角度方位对目标进行围捕打击，以实现多架无人机对单一目标的对抗模式。相比于传统的伪三维的地面机器人而言，无人机是一种真正意义上能在三维空间自由运动的空中机器人，这也要求无人机集群能够从三维空间中考虑如何全方位分布，从而避免目标逃脱。

1.2 群体机器人发展简述

国外对群体机器人研究较早，在上世纪四十年代，就有科学家提出如何通过简单个体构建复杂的系统行为的想法，在九十年代，以美国、欧盟、日本为代表的发达国家开始系统性的研究少量个体的多机器人项目，以美国 USC 大学的个体自组织群体行为机器人系统 Socially Mobile^[10]，日本 Nagoya 大学的机器人细胞元化自动重构系统 CBOT^[11]，以及欧盟的 MARTHA(Multiple Autonomous Robots for Transporting and Handling Application)群体搬运系统。

在进入二十一世纪后，得益于机电一体化的发展，单体机器人的尺寸以及单价均大幅度减。大规模群机器人系统的研究也随之兴起。自 2010 年开始，《International Conference Swarm Intelligence》^[12]开始创刊，并收获了越来越大的影响力。美国海军研究院也出现了以“小精灵”(Gremlins)^[13]为代表的一系列无人机集群项目（如图 1-2 所示）。在 2014 年，哈佛大学团队首次完成了数量级为千的群体机器人自组织行为

实验,使机器人仅通过局部感知即可在二维平面上生成特定的形状。同年, Vicsek 团队完成了在室外环境下十架无人机集群飞行的任务^[14], 并作为开创工作在 *Nature* 期刊进行了报道^[15]。该项利用了生物集群行为来实现无人机集群的群任务决策, 实现了无人机集群能够模仿鸟群行为。同时该模型不存在中心节点, 仅利用驱动粒子来对无人机个体进行驱动, 实现了无人机集群能够在含有 GPS 噪声、通讯延迟、通讯故障的环境下保证队形的稳定以及集群目标的跟踪。在 2015 年, DARPA 发布了《拒止环境中的协同作战》项目, 项目计划搭建一个模块化群体软件架构。该框架主要强调了“通讯拒止”这一概念, 与现有的标准相比, 该框架能够在低宽带乃至中断宽带的环境中执行, 以便在遇到电子对抗、通信拦截等不利条件下依旧保持无人机自身的对环境的感知, 并通过无人机个体之间的协助完成指定任务。目前美国无人机集群平台已覆盖了各个重量级。从几十克的“蝉”、几百克的“灰山鹑”到几千克的“郊狼”、几百千克的“小精灵”均用于无人机集群控制。



图 1-2 DARPA Gremlins 无人机

相较于国外,国内的群机器人系统近年来已然成为一个新的研究热点。目前我国众多高校已经成立了与群体机器人相关的项目组,例如:哈尔滨工业大学的群体机器人足球平台 MAS^[16],南开大学对群机器人编队控制进行了相关研究^[17]。而在无人机集群方面,国内北京航空航天大学^[17]、国防科技大学^[18]、电子科技科学研究院^[19]等团队也在这方面做出了相关工作。其中,中国电子科技集团科学研究院在 2017 年于清华大学等高效企业合作,完成了 119 架无人机的飞行与编队。而该团队在 2018 年创下了 200 架的固定翼无人机集群飞行记录。从 2005 年开始,中国与美国在无人机集群方面的竞争已然展开。美国投放的“灰山鹑”无人机编队在 2016 年完成了集群决策、自修复、自适应编队等任务,这也是目前公认的无人机编队最接近实战的一次编队飞行试验。虽然目前中国在数量上展示领先,但是关键技术方面仍然与美国存在一

定的差距，尤其是系统集成验证方面仍然存在短板。

1.3 典型生物群体行为模型及特点

目前，大多数的群体决策方案是依据自然界中的生物体特有机制模仿得来，例如蚁群内部通过信息素来形成集群；蝗虫通过同类相食形成蝗虫大军，来促使群体相安全方向逃离；鸽群可以根据当前情况切换群体的飞行轨迹，来形成自组织的分层网络；雁群通过形成“V”型以节省个体在集群中所要消耗的能量，并方便集群中的视觉交流；狼群在缺少领导者后会自动从群体中分配最优的个体作为头狼，并组织群体之间的任务分配；鱼群不需要绝对的领导者，所有个体均按照自己的规则移动，并向着极值区域收敛；细菌可以根据细胞液的浓度差，自适应形成合适的围捕形态，并实现对目标的绞杀与吞噬；细胞内基因与基因之间也可以通过简单的表达形式来模拟出复杂的表现形式。本小节主要对自然界中的蚁群、鸽群、基因群三个群体控制模型进行阐述，并分析这些群体智能行为的特点。

1.3.1 蚁群优化控制模型

蚁群优化算法(Ant Colony Optimization, ACO)^[20]作为群体智能中最经典的一种近似优化方法，能够模仿蚁群觅食的行为策略。如图 1-3 所示，该方法通过蚂蚁在运动时遗留下来的信息素完成群体之间的局部通信。同时，这种信息素会随着时间的浓度不断降低，从而便于蚁群能根据信息素浓度的变化来自主选择出巢穴与食物之间较短的路径。蚁群算法通过模拟蚂蚁探索的行为来设计类似的离散优化模型。在该算法中，群体机器人会像蚂蚁一样在经过的路径上遗留下信息素，其余机器人会根据信息素浓度的大小来选择一个合适的路径，路径上的信息素浓度越强烈，选择该路径的机器人会越多。同时这些机器人也会遗留下信息素以增强该条路径下的信息素浓度，从而形成一个正反馈，保证机器人能够根据信息素浓度选择出从起点到目标的最佳路径。从广义上来讲，蚁群算法主要通过迭代下述两个步骤来解决问题：1)候选一个信息素模型，当中需要含有信息素重要因子，信息素挥发因子，启发函数重要度因子来控制蚂蚁到下一步的转移概率。2)根据转移概率来选择机器人路径偏好，并不断正增强路径浓度信息，使结果落在高质量区域上。蚁群算法作为一种用于解决 TSP 问题的常见方法，其在调度问题，行车路线问题等诸多优化问题上均有良好的表现。但是其作为传统的二维路径规划问题，在应对无人机集群这类三维场景表现有些乏力。




图 1-3 蚁群优化控制算法流程

1.3.2 鸽群机制编队模型

如图 1-4 所示, 鸽群优化算法(Pigeon-inspired Optimization, PIO)的结构来源于自然界的鸽群行为, 该行为机制中个体之间存在有严格的等级关系。鸽群的层级机制有助于三维空间中多架无人机能够在飞行中保持稳定构型或稳定集群, 并能根据任务来动态的调整自身的队形, 以体现无人机群体个体与个体之间的协同一致性。鸽群不同于一般陆地上群体的单一首领机制(如狼群), 鸽群由于自身个体的通讯距离及视野存在一定的显示, 每个鸽子不能实时的发现头鸽。同时鸽群个体之间并不是同级关系, 通过严格的等级显示, 可以大幅降低信息交流带来的通讯压力。针对这一原理 Duan 等人^[21]于 2014 年提出了鸽群算法, 该算法主要通过两种不同的算子模型来模仿鸽子寻找目标的途径和方式: 1)首先根据地图和指南针算子, 来模仿鸽子在脑中形成地图的过程, 该算子随着个体距离目标的距离逐渐变近, 会逐步降低其影响因子, 来减少该群体算法对地图与磁场的依赖; 2)其次根据地标算子, 该部分需要对算法的探索能力进行优化, 利用地标算子来模仿鸽子靠近目标后根据地标进行导航的功能。在地标算子阶段, 算法会对该种群进行迭代, 将距离目标较远的机器人舍弃, 并将其余机器人的中心位置当做地标再次进行飞行, 直至收敛。但是该集群方式并不是一种去中心化的集群方式, 在面对无人机集群受到打击后, 该机制的无人机编队难以快速恢复。




图 1-4 鸽群编队控制模型算法

1.3.3 细胞基因调控模型

生物细胞内部均带有遗传信息，但是相同的基因却能在不同生物之间产生不同的表新形式。受此启发，人们根据基因能够精准控制细胞表现形式设计出了一套元件库，并通过元件库的连接来表示不同机器人的功能。细胞内的基因表达能够在面对外部环境刺激的前提下所做出不同的反馈，一般这种反馈分成两种：正调控描述了这些调控基因能够给环境带来正向反馈；而逆调控则是提供反向反馈。通过正向反馈与逆向反馈来综合表达出该细胞对于环境的综合反馈，从而体现出复杂的生物特性。同时如图 1-5 所示的基因调控网络(Gene Regulatory Network, GRN)作为一种细胞个体的表达形式，映射到机器人上能够完整的体现出去中心化。根据细胞基因这一特性，Jin 等人^[22]讨论了在多机器人系统中如何通过局部交互预测出新的行为，并通过相对简单的局部相互作用，在一个未知的环境中产生复杂且稳定的行为。文中还将基因调控网络应用到智能群体机器人系统中，利用分布式 GRN 的多机器人构造算法，使多个机器人可以自动形成不同的预定形状，并在动态环境下自适应地进行组织。该模型相较于蚁群算法与鸽群算法而言更加偏向于无中心化群体控制模型，同时不同的基因型的结合能组合成数以亿计的可能，便于群体机器人在不同的环境中可以根据自身的表现形式来分配不同的工作并能涌现出合适的群体行为。




图 1-5 基因调控网络群体聚合形态生成模型

1.3.4 群体智能行为特点

群机器人系统(SRSs)作为近年来研究的热点,始终围绕着如何将具有简单行为的低成本机器人,并利用该集群机器人自身有限的功能和性能^[23]做出单个复杂机器人无法完成的复杂任务。同样群机器人系统因为其在环境中具有较好的稳定性,可以实时扩展机器人集群规模并且拥有低廉的制造成本等优点,被广泛应用于目标搜索救援^{[24][25]}、卫星交互通信^{[26][27]}、编队模式变换^{[28][29]}、相互实现无源定位^{[30][31]}等领域。

大多数研究认为群体智能行为可以划分为五个基本原则^[32]:邻近原则,这要求群体机器人之间能够进行简单的空间计算,并向着最优的方向驱动;品质原则,这要求群体机器人需要评估自身位置状态在环境中的质量,便于群体的选择与淘汰;多样性原则,这要求群体在探索过程时有一定的随机性,避免陷入局部最优;稳定性原则,这要求机器人集群行为能够适应绝大多数场景,从而尽量避免环境发生变化时需要调整自身网络的行为;适应性原则,这要求机器人集群在环境变化时能够以较小的代价适当改变自身的行为,从而保证最优的行为策略。

因此,作为群体智能,一般会具有以下几个特点^[33]:

1)群体内部可以实现去中心化,同时群体内部的个体只具备简单的局部感知、规划能力,并遵循简单的行为规则。群体中个体可以通过与相邻个体之间的简单信息交互完成自身状态的改变以适应当前的环境。该系统由于不存在中心,所以当群体中机器人受到部分打击后拥有一定的自愈性,仍然能够完成任务。

2)群体个体的行为策略均是简单的,在群体中,每个个体尤其只有一种或者几种

的状态以根据当前环境的情况来做出相应的反应。通过这种简单的群体行为来产生复杂的群体行为。作为集群系统不是简单的个体行为相加，而是通过集群之间简单的通讯来完成集群整体的组织、决策、合作、运动，从而来完成群体能力的倍增。

3)群体中个体与个体之间的相互作用是灵活地且稳定的，当面对环境的变化时，群体机器人仅需要去对某些参数进行动态调整来继续适应新的环境。此外群体机器人的稳定性和灵活性往往是矛盾的，这就需要模型达到一个动态均衡的临界点。从而确保机器人群体能保持稳定性的同时也兼具灵活性。

1.4 主要研究内容及结构安排

本文主要基于三维基因调控网络对群体智能机器人进行研究。针对三维空间中无人集群在复杂环境中对目标的动态围捕问题，从三维全局基因调控网络入手，并进一步设计相应的局部基因调控网络，以更加符合实战场景。值得注意的是相较于以鸽群、雁群算法为代表的群体运动控制模型，基因调控网络利用分层的模型结构，使其更加适应复杂的、动态的环境。文章总共分为五个部分，由传统的二维群体形态网络进阶到三维群体调控网络，框架如下：

第一章首先介绍了群体机器人课题研究的背景与意义，指出了以无人机为代表的群体机器人研究的重要性。之后简要介绍了国内外群体机器人发展，并对比了中美之间无人机集群的优势与差异，最后从昆虫，动物，微生物三个层面选取代表性的算法进行阐述，并总结归纳出群体智能所需要的行为特点。最后阐述主要的研究内容以及下文的结构安排。

第二章针对生物群体行为到机器人群体模型国内外的研究进行讨论。之后分别从机器人编队和机器人围捕分别进行阐述，从而对比出两者之间的相同与不同点。

第三章针对基因调控网络进行阐述，并从基因调控网络元件库和基因调控网络的适应度函数两个方面进行阐述。在此基础上，我们会针对性的在全局坐标系下提出基于三维基因调控网络的群体聚合形态自适应生成方法。并来验证该方法是否适用于三维空间场景。

第四章主要介绍了针对上文在全局坐标系下提出基于三维基因调控网络的群体聚合形态自适应生成方法的改进，并提出的适用于无人机集群的三维局部分布式基因调控网络模型。在本章节会全面剖析该模型相较于全局坐标系下的不同点，并通过实验对比来验证该三维局部基因调控网络与三维全局基因调控网络性能。

第五章对本文所给出的算法及实验做出分析总结，并证明该方法在针对以无人机为代表的群体机器人在三维空间中的可行性与有效性。

第2章 从生物群体行为到机器人群体模型的国内外研究现状

机器人的群体行为研究从上世纪开始就有了一系列研究,例如形态发生(Morphogenesis)^{[34][35]}、反应扩散模型(Reaction-Diffusion Model)^{[36][37]}、趋化性(Chemotaxis)^[38]和基因调控网络(Gene Regulatory Network, GRN)^[39]等。而这些都属于机器人集群模式的范畴,这类集群行为作为群体智能中重要的一类,需要集群机器人自主获取环境中的信息,并根据信息完成特定模式的转换。下文中我们将针对机器人编队控制和围捕控制两个方面对国内外的研究现状进行阐述。

2.1 群体机器人编队控制

机器人编队作为群体模式生成重要组成部分,一直以来受到了广泛的关注。机器人的编队控制旨在通过控制机器人的方向、速度从而实现与群体中其余个体保持相对一致性。文献^[40]提出了多智能体编队控制策略,通过群体机器人之间的选择一致性,来将选择一致性算法应用到群体编队当中。文献^[41]中提出了一种基于 PSO 的群体机器人方法,通过 PSO 的参数优化可以使群体机器人在未知环境下实现编队导航控制。文献^[42]采用了领导跟随的方法来实现多无人机在快速编队方面的应用。该方法控制简单,编队稳定。能够较好的完成机器人快速编队与动态避障的要求,文献^[43]采用了虚拟机器人和人工势场法相结合的方法,实现了水下机器人集群的编队控制,并针对不同的任务对应不同的行为。该方法同样设计相对简单,并能保持基础的避免碰撞、保持距离等功能。这些方法作为一种简单的行为策略,能够保证机器人群体自身的安全,同时为在复杂环境中实现群体的围捕任务打下了基础。

2.2 群体机器人围捕控制

群体机器人围捕指的是机器人根据围捕目标的信息来完成围捕的形态生成。这种形态是自适应生成的,因此并不需要中心来下发形态生成指令^[23]。然而现有的大多数群体围捕模式需要预定义一个或者几个合适的目标形状,并更具环境的不同选择群体形态,这样就局限了围捕的场景,从而无法在真实的未知场景中满足目标围捕的需求^[44]。为此 Beta 和 Kumar^[45]创新性的提出了一套群体机器人的编队控制方法。该方法通过设计两个简单的形状并自适应调整目标周围的形状大小来主动地适应不同的场

景。Cheah 等人^[46]则是根据人工势场来实现机器人能够在一定范围内运动，并依据浓度场信息生成群体控制形状。同时，浓度场的差值也限制了机器人彼此之间能够保持最小的距离。进一步，Jin 等人^[47]根据细胞浓度的差值来将群体机器人的模式生成和运动控制分离开来，并设计出一种分级基因调控网络(H-GRN)。通过上下两层结构，使上层用于生成群体聚合形态，下层用于对群体机器人实现控制，但是由于没有考虑障碍物的影响，所以 Jin 的工作只能用于无障碍物的场景。为了躲避障碍物，Peng 等人^[48]对 H-GRN 的下层去做了进一步的改进，但是由于上层仍然使用的是 H-GRN 的上层，这也导致了该模型在复杂场景下仍然无法自适应环境。王诏君^[49]提出了一种基于 GP 进化算法的基因调控网络 (GP-GRN)，这套算法可以有效地在二维场景中完成复杂的群体聚合以及目标的围捕的复杂群体任务。综上所述，在围捕方面大多数工作是围绕着二维环境下的目标围捕任务，也有一些团队做了三维空间下的目标围捕的相关研究。

Fedele^[50]提出了一种适用于多维空间的智能群体运动学模型，在有限时间内对目标进行轨迹跟踪，并分析个体与群体的关系，证实了该运动学模型在三维环境中的可行性，但该模型没有考虑障碍物，具有一定的局限性。陈^[51]提出利用 FMM(fast marching method)与改进的 GBNN(Glasius biological inspired neural network)模型相结合，从而完成了水下单一机器人的路径规划功能，并通过预先设定的群体形态来实现对水下静止目标的围捕，这种方法无法同时执行群体路径规划与围捕。在基因调控网络方面，孟等人^[52]通过 GRN 模型使群体机器人进行形态上的变化，提出了一种邻域自适应机制，使机器人均匀地部署在人工设计的目标形状周围，在没有集中控制器的情况下，群体机器人可以形成各种三维形状。实验结果表明了在三维空间中 GRN 模型可以较好地完成编队飞行任务。同时 Braccini^[53]综述了基于 GRN 在机器人方面的一些应用研究，并指出基于 GRN 模型生成三维空间群体聚合形态的可行性。

2.3 本章小结

本章首先对群体机器人编队控制进行了介绍，并进一步引入到群体机器人围捕控制任务中。介绍了以二维 GRN 为代表的传统群体机器人围捕方案，也阐述了近年来三维环境中的群体围捕任务。由此可以推断出传统的基因调控网络模型(Gene Regulatory Network, GRN)会导致机器人群体聚合形态在三维空间中不具备泛化性，二维的围捕策略目前已经越来越不适用于以群体无人机为代表的三维群体围捕任务。

第3章 三维空间下群体聚合形态自动生成框架

目前, 现有的基因调控网络(Genetic Regulatory Networks, GRN)的设计仍然局限于二维环境中。这也导致了基因调控网络无法在以无人机为代表的三维群体机器人中完成应用。为此本文针对三维全局场景设计出一种三维全局 GRN 模型, 并将其应用到三维环境中。根据仿真结果显示, 该模型可以较好地应用在三维环境中, 并在经过复杂场景的跟随后无人机仍然可以较好地完成围捕。

3.1 基因调控网络简介

基因调控网络作为一种细胞中调节剂的集合, 常常被用于细胞与细胞之间的相互作用, 以控制 mRNA 和蛋白质的基因表达水平。GRN 在形态发生和结构创建中也起着核心作用。在单细胞生物中, 调节网络会根据外部环境去呈现出不同的表现形式, 从而能在给定时间优化细胞以让个体在此环境中存活。在多细胞动物中, 控制体形的基因之间也采用了相同的原理^[54]。每当细胞分裂时, 随之都会产生两个细胞, 尽管它们完全包含相同的基因组, 但它们在基因的表现型和蛋白质的制造方面可能会有所不同。多细胞动物通过基因调控网络系统可以告诉细胞来抑制或激活不同的基因, 从而告诉细胞个体自身需要分化成为哪种细胞。研究表明, 细胞可以根据自身所处的环境来创造出特定的转化, 并于特定环境阈值水平以上时才打开基因。近年来的研究发现, 基因调控网络的层次结构不但在细胞的基因表达中起着重要作用^[55], 而且会影响到个体的行为模式。例如果蝇自身的行为模式策略也是由一个分层基因调控网络决定的^[56]。由此可见, 分层 GRN 可以生成稳定且复杂模式和行为^[57], 从而产生更好的适应性和进化性。T Taylor^[58]与 H Guo^[22]这两个团队提供了大量与 GRN 相关的研究进展。并尝试通过设计一套完善的分层基因调控网络(GRN)来代替复杂繁琐的设计网络实现对群体机器人的控制。

GRN 相较于传统的群体控制而言, 具有以下优点: 1) 可以根据场地的大小动态调整分辨率; 2) 不需要判断是否存在目标及障碍物, 网络模型可以根据人工势场动态的生成浓度图, 集群机器人只需要根据浓度场信息完成集群机器人的运动控制; 3) 基因调控网络分为上下层, 相较于传统的群体控制而言, 该控制可以有效地对网络的功能进行划分, 从而避免模型生成溶于运动控制中, 难以对模型进行解释。

3.2 自定义元件库及使用






在如何自动化构建基因调控网络模型的问题中, 尽管学术界对基因编程包括基因调控网络模型进行了大量的研究, 智能化基因调控网络模型依然存在元件库不充分, 设计结构不通用等亟需解决的问题。首先, 在基因编程框架的构建过程中, 本文发现现有的元件库并不够丰富, 这对于设计一款能够实时动态适应动态复杂作战环境的基因调控网络模型具有极大的局限性。同时缺少足够的元件也将会限制基因编程自动化建立模型的多样性, 从而阻碍生成的基因调控网络在群体规模较大、模式构成多样和外界环境多变等不确定因素条件下群体智能聚合与涌现的性能。其次, 在选定基因调控网络模型库来设计模型时, 适应度评价函数的选择是实现种群进化的关键所在, 也是基因编程必不可少的步骤。进化准则合适与否, 直接关系到利用进化自动设计出的基因调控网络模型的优劣。再者, 我们的目标是实现基因调控网络模型拓扑结构与参数的同时优化, 参数的合适设定对简化群体智能聚合与涌现的过程起到了积极作用, 极大缩减了群体机器人完成任务的时间, 减少群体机器人完成任务时消耗的能耗大小, 只需单次优化, 即可获得多个在目标上具有不同偏好的新型基因调控网络模型。最后, 基因调控网络模型的输入输出应包含明确的内容设定, 研究发现, 现有的模型输入输出设定并没有完整的整合一套适用于群体智能聚合与涌现任务, 这对于实现无人集群协同作战任务是极为不利的。




为了解决这些问题, 针对现有基因调控网络模型相关数学模型元件库的分析, 本文结合生物体内基因与基因之间的关系, 提出了新的元件库, 基因 x_1 对基因 x_2 的激活(Positive)或是抑制(Negative), 基因 x_1 和 x_2 之间的关系(AND 和 OR)表达对基因 y 表达的影响。在适应度函数选择上, 本文首先基于原有基因调控网络模型设定的适应度函数作为初始函数, 并在现有的适应度评价基础上, 输入目标的位置信息, 从而对基因调控网络模型进行优化微调。这一工作的目的是为了用于实现实验对比, 相比较于现有的基因调控网络模型而言, 突出在遇到复杂场景后群体机器人围捕的目标的能力。参数的优化工作, 因为基因编程本身具有的特性, 在这里我们随机给以一定范围内的数, 通过迭代, 从而寻得基因调控网络模型的最优参数。


3.2.1 基因调控网络的基本元件库

近年来生物界对基因以及蛋白质的研究发现^[59-60]生物的蛋白质和基因间之间存在有逻辑关系。同时这些逻辑关系控制着蛋白质和基因表达。受生物界的影响，群体机器人的基因调控网络控制元件可以被归纳为十种逻辑关系：

表 2-1 基本元件库

元件名称	描述	关系方程	图例
Positive	基因 x 激活基因 y 。	$\frac{dy}{dx} = -y + sig(x, \theta, k)$ $sig(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x 为输入量。	
Negative	基因 x 抑制基因 y 。	$\frac{dy}{dx} = -y + [1 - sig(x, \theta, k)]$ $sig(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x 为输入量。	
AND	当基因 x_1 和 x_2 同时表达时, 则基因 y 表达。	$\frac{dy}{dx} = -y + [1 - sig(x_1 * x_2, \theta, k)]$ $sig(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
NAND	当基因 x_1 不表达或基因 x_2 不表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + sig(x_1 * x_2, \theta, k)$ $sig(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
OR	当基因 x_1 或者基因 x_2 表达时, 则基	$\frac{dy}{dx} = -y + [1 - sig(x_1 + x_2, \theta, k)]$ $sig(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$	

	因 y 表达。	θ, k 为可调变量, x_1, x_2 为输入量。	
NOR	当基因 x_1 不表达并且基因 x_2 不表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + [1 - \text{sig}(x_1 + x_2, \theta, k)]$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
ANDN	当基因 x_1 表达并且基因 x_2 不表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + \text{sig}(x_1 * (1 - x_2), \theta, k)$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
	当基因 x_1 不表达并且基因 x_2 表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + \text{sig}((1 - x_1) * x_2, \theta, k)$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
ORN	当基因 x_1 表达或基因 x_2 不表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + \text{sig}(x_1 + (1 - x_2), \theta, k)$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
	当基因 x_1 不表达或基因 x_2 表达时, 则基因 y 表达	$\frac{dy}{dt} = -y + \text{sig}((1 - x_1) + x_2, \theta, k)$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}}$ θ, k 为可调变量, x_1, x_2 为输入量。	
XOR	当基因 x_1 和基因 x_2 都表	$\frac{dy}{dt} = -y + [1 - \text{sig}(x_1 * (1 - x_2), \theta, k) - \text{sig}((1 - x_1) * x_2, \theta, k)]$	

	达，或基因 x_1 和基因 x_2 都不表达时，则基因 y 表达	$\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x - \theta)}}$ θ, k 为可调变量， x_1, x_2 为输入量。	
XNOR	当基因 x_1 和基因 x_2 一个表达，但基因 x_1 和基因 x_2 不同时表达时，则基因 y 表达	$\frac{dy}{dt} = -y + \left[1 - \text{sig}(x_1 * (1 - x_2), \theta, k) - \text{sig}((1 - x_1) * x_2, \theta, k) \right]$ $\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x - \theta)}}$ θ, k 为可调变量， x_1, x_2 为输入量。	

如图 3-1 所示，根据上述的基因调控网络元件库我们可以自由组合获得不同表现形式的基因调控网络模型。




图 3-1. 基因编程利用基本元件库构建基因调控网络模型示意图

为了建立群体机器人的基因调控网络模型，首先需要对网络的输出与输入进行定义。输入元件集合包括：目标 T (Target)，障碍 O (Obstacle)，其输出则为当前机器人所应该形成的形态方程 M 。其特点如下表 2 所示：

表 2：输入输出元件

元件名称	描述	属性参数	图例
目标 T	指示当前个体所在位置的检测范围内是否有目标。若有，则为给定的正数，否则，为 0。	$\gamma(X) = \begin{cases} \lambda, & X = 1 \\ 0, & X = 0 \end{cases}$ X 为当前机器人个体在探测范围内进行检测的结果。 $\gamma(X)$ 为检测结果的指示函数，如果检测到区域内存在目标，则取值为常数 λ ，否则为 0。	
障碍 O	当前个体在给定阈值范围内检测到的障碍物距离总和。	$O_i = \sum_{k=1}^{N_{obs}} \frac{g_i - g_k}{ g_i - g_k }$ N_{obs} 为个体在碰撞警戒范围内检测到的障碍物个数， q_k 为其中第 k 个障碍物的位置。	
形态方程 M	可以直接输入人为设计的模式方程信息。	根据元件库以及自适应度函数综合得到的机器人应到达的点。	

3.2.2 基因调控网络适应度函数定义

适应度函数是用来评价一个模型在特定场景中的优劣的评价指标。在基因调控网络的稳步任务中，我们不希望围捕机器人距离目标太近或者太远，所以需要通过 d_{min} 和 d_{max} 来约束围捕机器人到目标的距离范围，从而使机器人集群落在合理的范围内。在环境中，障碍物也是会影响围捕性能好坏的因素，为了保证围捕机器人自身的安全，本文将障碍物考虑进包围圈中，并设置围捕机器人到障碍物的最小距离 d_{min}^{obs} 。如下则是在三维空间中的评判指标：

$$f_1 = \sum_{i=1}^{N_p} \sum_{j=1}^{N_t} \frac{\text{sig}(d_{pt}^{ij}, d_{max}, k_1) + \text{sig}(d_{min}, d_{pt}^{ij}, k_2)}{N_p N_t} + \sum_{i=1}^{N_p} \sum_{k=1}^{N_o} \frac{\text{sig}(d_{min}^{obs}, d_{po}^{ik}, k_3)}{N_p N_o} \quad (3-1)$$

其中， N_p 、 N_t 和 N_o 分别为三维空间中围捕机器人的个数、需要围捕的目标个数和

在环境中障碍物个数。 d_{pi}^{ij} 为第 i 个围捕机器人到第 j 个目标的距离； d_{po}^{ik} 为第 i 个围捕机器人到第 k 个障碍物的距离； k_1 、 k_2 和 k_3 为参数。

3.3 基于三维基因调控网络的群体模式生成方法

在本节中，基于王诏君^[50]做的二维基因调控网络提出一种适用于三维空间的群体跟踪与围捕方法，并针对集群围捕任务测试了该方法在三维空间复杂场景下的表现。为了表现出三维基因调控网络的智能机器人群体聚合与控制方法的性能，本文分别在 Matlab 和 V-rep 平台来设计出模拟场景，来验证在加入物理特性前后该模型的性能。以证明在全局三维空间下智能机器人群体聚合与控制方法的可行性，并为第四章三维局部分布式基因调控网络模型做好准备。

3.3.1 基于全局信息的三维聚合形态自适应生成

目前现有的群体聚合形态生成基因调控网络结构一般都是使用 Positive、Negative、AND、OR 这四个基础元件库进行排列组合并设计合适的基因调控网络，虽然这些基础原件可以完成一些简单任务。但是只能完成障碍物共融的围捕策略，不能考虑到障碍物对围捕形态的影响，这也导致这类模型难以适应三维空间中围捕任务，具有一定的局限性。为此本文提出了一种基于三维基因调控网络的群体模式生成方法，图 3-2 为该模式的整体框架，其中每一个细胞内部都是一个完整的基因调控网络整体框架，细胞与细胞之间存在一定的信息交流。




图 3-2 群体聚合形态自动生成方法示意图

图 3-2 中目标的位置和障碍物的位置将作为基因调控网络两个先验条件,来生成全局浓度地图。下一步就是需要将浓度地图转化为群体形态:1)根据提供的障碍物与目标的位置以及基因调控函数参数来生成含有障碍物的浓度梯度空间;2)在得到浓度梯度空间信息后,该框架可以通过自主判断不同的等势线所带来的形态梯度的优劣,并根据形态梯度的形状来选择出合适的阈值,从而动态的调节群体机器人的目标围捕形状,从而驱使机器人能够在复杂环境中自适应运动形成复杂的群体聚合形态。

在上层中,本文设计了一种简单的群体模式生成模型(如图 3-3 所示),在该模型中,本文使用 XNOR 作为唯一的网络组件,即可使基因调控网络生成复杂的群体围捕模式。XNOR 作为寻找到的一个基础原件,我们发现该元件的二元选择性对于这种含有目标与障碍物的场景非常合适,其可以有效的对目标和障碍物进行有效的区分,通过生成的浓度场,该方法能够有效的驱使机器人向目标方向移动,并停留在自动生成的群体集合形态上。从而生成一个合适的含有障碍物信息的浓度梯度空间。

$$T = \sum_{i=1}^{N_i} \nabla^2 T_i + \gamma_i - T_i \quad (3-2)$$

$$O = \sum_{j=1}^{N_o} \nabla^2 O_j + \beta_j - j \quad (3-3)$$

$$\frac{dM}{dt} = -M + \text{sig}(1 - T * T, \theta, k) + \text{sig}(O * O, \theta, k) \quad (3-4)$$

$$\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}} \quad (3-5)$$

式(3-2)和(3-3)中, T_i 和 O_j 分别表示第 i 个目标和第 j 个障碍物产生的形态梯度,用以代表每个机器人周围的目标和障碍物的信息; T 和 O 分别为所有目标和障碍物产生的综合蛋白质浓度; ∇^2 为 Laplacian 算子,该算子为二阶导数,可以有效地表示出目标 T_i 和障碍物 O_j 所在形态梯度空间状态,可视为生物系统中的蛋白质扩散过程; γ_i 作为当前时刻群体机器人获得的目标位置; β_j 作为当前时刻群体机器人获得的障碍物位置; θ 和 k 为调控参数。式(3-4)表示在经过障碍物以及目标的输入后,三维基因调控网络模型上层可以输出一个含有障碍物的梯度空间。式(3-4)中的 $\text{sig}()$ 函数具体表现形式如式(3-5)所示。式(3-5)主要操作是归一化,从而确保浓度梯度空间可以稳定在一定范围内,并不会随着环境的变化而发生大幅度变化。如果当目标周围没有障碍物时,式子(3-4)可以进一步简化得到式子(3-6)。将 $\text{sig}(O * O, \theta, k)$ 部分可以舍去。由此可见该 XNOR 模型能够随意的在不同场景中进行切换,从而保证机器人在含有障碍物环境下的性能。

$$\frac{dM}{dt} = -M + \text{sig}(1 - T * T, \theta, k) \quad (3-6)$$




图 3-3 XNOR 模型图

为了解释形态方程 M 在三维空间中形成的效果。本文简化了场景来说明该问题，将只保留一个目标和一个障碍物，且这两者之间不存在围捕机器人的互相影响。如图 3-4 所示，本文设置的障碍物在目标无人机的下方，通过将浓度场分别沿着目标的三个维度(X, Y, Z)进行切分，从而得到浓度场在 X 、 Y 、 Z 三个维度下的浓度图。由图可知，在经过 GRN 上层的 XNOR 模块作用后，目标呈凹陷状，障碍物呈凸起状，围捕机器人通过浓度差从高到低来进行运动，并逐渐逼近目标。最后该模型根据预先设定好的阈值信息来选择该浓度梯度空间中自适应生成的群体聚合形态。




图 3-4 三个维度下 XNOR 生成的浓度梯度空间

3.3.2 群体机器人群体聚合形态的控制与形成

在下层中，本文将根据已有的群体聚合形态在浓度地图中的位置，来驱动机器人沿着梯度空间浓度下降的方向移动。因此，我们需要对三维空间下的运动方向进行分解。

如图 3-5 所示，设三维空间中 P 点的坐标为 (x_p, y_p, z_p) ，该点到 xoy 平面上的投影为 $p'(x_p, y_p, 0)$ 。利用三角形反正切函数可以求得 $\beta \in (-\frac{\pi}{2}, \frac{\pi}{2})$ 的值：

$$\beta = \arctan\left(\frac{z_p}{\sqrt{x_p^2 + y_p^2}}\right) \quad (3-7)$$

将点 $p'(x_p, y_p, 0)$ 向 x 轴做垂线得到 $P''(y_p, 0, 0)$ ，利用三角形反正切函数可求得 $\alpha \in (-\pi, \pi)$ 的值：

$$\alpha = \begin{cases} \arctan(\frac{x_p}{y_p}), & y_p > 0 \\ \arctan(\frac{x_p}{y_p}) + \pi, & y_p < 0, x_p < 0 \\ \arctan(\frac{x_p}{y_p}) - \pi, & y_p < 0, x_p > 0 \\ +\frac{\pi}{2}, & y_p = 0, x_p < 0 \\ -\frac{\pi}{2}, & y_p = 0, x_p > 0 \end{cases} \quad (3-8)$$




图 3-5 三维空间分解示意图

同时，本文依据五个分向量^[61]来指引机器人运动。其运动速度如下：

$$\frac{dP_i}{dt} = (d_i + n_i + z_i + u_i) \text{ or } b_i \quad (3-9)$$

式中，分量 d_i 表示目标对第 i 个围捕机器人的斥力，以防机器人集群过于靠近目标（实验中欧式距离小于 $4m$ 时触发）；分量 n_i 表示第 i 个机器人与除他以外围捕机器人的斥力，当机器人与其他机器人之间密度过大时（实验中欧式距离小于 $2m$ 时触发），机器人远离同类；分量 z_i 表示第 i 个机器人在受到浓度场时产生的引力，该引力以自适应包围圈作为阈值，来使围捕机器人向包围圈附近靠拢；分量 u_i 表示第 i 个机器人受周围浓度的影响产生的分力，这样可以避免围捕机器人集群都聚集在最优点附近，无法实现良好的围捕；分量 b_i 表示机器人与障碍物的排斥分力，当与障碍物距离过近时，则单独触发障碍物排斥力，分量 b_i 与其余四个分力不会同时触发，分量 b_i 仅仅作作为类似传感器的强行避障使用，正常情况并不参与，仅作为紧急避障使用。




图 3-6 机器人综合速度的五个控制分量

3.3.3 群体机器人评价指标与效能

在本节中，本文通过 MATLAB 与 V-rep 仿真实验来验证在三维场景中该方法的有效性，并针对性的对三种评价指标与步长的关系进行分析。这三种评价指标分别是：围捕机器人与目标的平均距离 D_a ；围捕机器人收敛误差 $\phi_s(g)$ ；以及围捕机器人包围圈的包围强度 D_s 。同时，在仿真场景方面，本文将仿真实验参数设置如下：

- 仿真场景大小为 $200m \times 200m$ ，分辨精度为 $10cm$ ；
- 群体机器人个数为 20 个，运动控制精度为 $1cm$ ；

- c) 目标个数为 1 个，障碍物数目大于 4；
- d) 群体机器人移动速度为 1 个单位，而目标机器人移动速度为群体机器人的一半；

本文的目标围捕任务主要包含以下两个步骤：1)根据当前时刻的目标信息素浓度值和障碍物信息素浓度值生成包围目标的最优形态，并得到每个机器人在三维空间中的运动分量； 2)根据运动分量来控制群体机器人分布到当前时刻最优的形态上。

在此基础上，本研究针对性的作了如下合理假设：

- 1) 在三维空间中，机器人保持匀速运行的，同时机器人可以在全局坐标系下进行简单的位姿信息交互；
- 2) 对于障碍物与目标，机器人可以通过视觉等方法实现目标捕获，并能将目标位置映射到全局坐标系下；
- 3) 群体围捕机器人的速度大于目标的速度，以保证围捕机器人能够追上目标并对目标进行围捕；
- 4) 所有围捕机器人都是同质且去中心化的，每个机器人可以分布式布置。

此外，为了衡量所提方法的性能，本文定义了以下指标：1)围捕机器人与目标的平均距离 D_a ，2)围捕机器人收敛误差 ϕ_s ，3)围捕机器人包围球面的包围强度 D_s 。具体说明如下：

围捕机器人与目标的平均距离 D_a 表示了群体机器人相对于目标的平均距离，即

$$D_a = \left(\sum_{i=1}^{N_r} \min(d(g_i)) \right) / N_r \quad (3-10)$$

式中， N_r 表示围捕机器人个数， $d(g_i)$ 表示第 i 个围捕机器人与所有目标的相对位置。如果平均距离 D_a 收敛到一定值，则说明该系统处于稳定状态。

围捕机器人收敛误差 ϕ_s 用于判断在三维空间中机器人通过基因调控网络自适应运动到指定包围球面上的能力，即

$$\phi_s = \sum_{i=1}^{N_r} f(g_i) \quad (3-11)$$

式中， $f(g_i)$ 为围捕形态的隐函数，表示第 i 个围捕机器人在三维空间中的浓度与设定的围捕形态浓度之差。如果 ϕ_s 逼近为 0，则说明围捕机器人群体聚合能力良好，基本均落在包围目标的球面上。

围捕机器人包围球面的包围强度 D_s 表示了机器人在包围球面上的均匀性，如公式(3)所示。为了验证该均匀性，本文首先使用了墨卡托投影法^[62]，将目标球面切分为边长为 R 的正方形。

$$\begin{aligned}
 Plane_x &= R * \sigma \\
 Plane_y &= R * \ln(\tan(\pi / 4 + \gamma / 2)) \\
 D_s &= (\bigcup_{i=1}^{N_r} f_i(Plane_x, Plane_y) / R^2)
 \end{aligned} \tag{3-12}$$

式中， σ 表示球体的经度角， γ 表示球体的纬度角， $Plane_x$ 为映射到墨卡托平面坐标系的 x 轴， $Plane_y$ 为映射到墨卡托平面坐标系的 y 轴。 $f_i(Plane_x, Plane_y)$ 表示在墨卡托平面坐标系下第 i 个围捕机器人所在区域的影响范围，本文设置影响范围参数是 30。 D_s 越大，表示围捕机器人在包围球面上具有更好的均匀性。

3.3.4 实验与分析

图 3-7 展示了在 Matlab 仿真中的围捕场景，在该场景中，目标的移动速度为 0.4m/s，障碍物均处于静止状态。




图 3-7 群体机器人动态围捕过程

在 $step=1$ 时；围捕机器人处于初始状态，并随机分布在目标的左侧，我们可以看到在此时围捕机器人随机分布在目标周围，此时的围捕效果。在 $step=5$ ，机器人经过第一个障碍物，两个障碍物均位于目标下方 2m 的位置，此时围捕机器人在跟踪目标的同时会想着除了目标下方的其他方向进行运动，从而保证该三维基因调控网络可以

动态自适应不同的环境；在 $\text{step}=240$ 时，我们可以发现由于刚经过狭窄通道，并处于第四个障碍物附近，此时围捕机器人处于追踪阶段，更偏向目标机器人后方。在 $\text{step}=75$ 和 $\text{step}=175$ 时，目标绕过中间的第二个和第三个障碍物，目标机器人会因为障碍物改变路径，同时围捕机器人会围捕目标的同时主动避障。在 $\text{step}=300$ 时，目标到达终点，围捕机器人在目标周围形成了良好的包围形态。由图可见，在三维场景中，围捕机器人在经过多个障碍物后，仍能稳定在目标形态附近，实现对目标的群体围捕。

为了模拟真实环境下群体机器人对目标的围捕行为，本文进一步使用 V-rep 平台搭建仿真场景来测试该方法的性能。V-rep 作为一款支持机器人运动学仿真的软件，该软件可以采用分布式的控制结构，通过对每个物体的嵌入式脚本、ROS 节点、BluezZero 节点、API 客户端控制等方法来验证在带有运动学后机器人和机器人算法的可行性。目前该软件越来越多的被用于多机器人写作场景，通过硬件控制，可以将仿真场景和实物进行实时交互。相较于 Matlab 平台，V-rep 平台加入的物理引擎可使场景更为真实。如图 3-8 所示，在场景中设有楼房，树林以及山丘等障碍物，并加入了带有运动学的机器人集群，来实现 V-rep 平台下围捕机器人对目标的围捕过程。从 $\text{step}=5$ 到 $\text{step}=240$ ，围捕机器人经过了山丘和树林两种障碍物。与 Matlab 场景相似，该方法能有效的控制围捕机器人在绕过障碍物的同时对目标(红色标出区域)进行持续跟踪；从实验结果可以看到，在 V-rep 中，该围捕机器人集群仍能对目标进行有效跟踪与围捕。在目标停止移动后($\text{step}=300$)，机器人能根据当前的浓度自适应形成包围球面来完成对目标的围捕。并最终得到与 Matlab 仿真类似的结果。由此可见，在 V-rep 仿真环境下，群体机器人面对复杂的任务场景仍具有良好的目标围捕表现。




图 3-8 V-rep 平台下的仿真实验结果

图 3-9(a)中本文对目标的轨迹进行了可视化，并选择了关键的四个点进行分析。图 3-9(b)(c)(d)分别显示了在相同时间步长下，围捕机器人与目标的平均距离 D_a 、围捕机器人收敛误差 ϕ_s 和围捕机器人包围球面的包围强度 D_s 的变化情况。根据 3.3.3 小节的相关计算公式，本文可以从时间维度对这些指标进行计算对比。从图 3-9 中可以看出，在第 5 帧和第 240 帧时，围捕机器人遇到了低矮障碍物，需要被迫爬升以围捕目标，此时 ϕ_s 与 D_a 都达到了一个峰值，且 D_s 处于谷值。此时由于场景的变化以及围捕机器人相互排斥，会导致较多的机器人被挤到外侧，所以会导致群体机器人到目标的平均距离 D_a 会上升，同时由于机器人靠近障碍物导致浓度场发生较大幅度的变化，机器人难以根据浓度场均匀散开，所以此时平均误差 ϕ_s 也处于较高的阶段。由于下方的区域没有机器人，所以目标机器人下方是不存在机器人围捕的， D_s 会因此大幅降低。但是结果中可以发现 D_s 依旧高于 30%，并能在十帧以内快速恢复至 50% 以上。这说明该算法中的围捕机器人在空间落差较大的环境中，依旧有较好的围捕性能。




图 3-9 机器人综合评价

在第 75 帧和第 175 帧时，图 3-9 (a)中的障碍物要高于目标，此时目标选择改变运动方向以躲避障碍物。从图 3-9 (b) (c)中我们可以看出，此时 ϕ_s 和 D_a 都有所上升，这说明当目标在通过狭窄通道时，机器人会动态改变围捕包围圈的形状，以适应不同的环境。图 3-9 (d)中的 D_s 也相应下降，这说明狭窄通道对目标围捕包围圈的形成有

一定的影响,从而导致机器人因为浓度场、障碍物等控制分量向其他方向挤压,从而导致平均距离 D_a 和平均误差 ϕ_s 会因此上升。但从结果中可以发现在 10 帧内各个数值又趋向于正常水平,说明在通过狭窄通道后,围捕机器人能够快速恢复围捕包围圈,同时机器人能较快的运动回包围圈上。由此可见该方法具有较强的自适应能力,在目标通过狭窄障碍物场景中表现良好,并能快速恢复。

在第 300 帧时,此时目标已经停止,并等待了一段时间,此时结果显示,围捕机器人大多均匀地分布在目标周围,形成了良好的包围效果。同时平均距离 D_a 已经收敛,稳定在一个较小值,此时说明机器人在目标周围形成包围的同时具有一定的距离,从而达到了一个动态的平衡。平均误差 ϕ_s 趋向于 0,说明此时的围捕机器人已经到达包围圈上,并保持稳定。包围强度 D_s 此时也稳定在 80%以上,由此可见在经过复杂场景后,该方法仍可以较好的对目标进行跟踪并围捕。适用于较为复杂的三维空间下的围捕任务。

3.4 本章小结

本章主要描述了一个三维空间下的群体聚合形态自动生成框架,近年来,在仅存在个体与个体、个体与环境之间信息交互的场景下,如何实现三维空间中的集群行为是急需解决的一大挑战。其原因是在群体智能机器人中二维环境下的群体机器人形态生成与控制仅仅是在真实场景下的一种简化,通常仅考虑在水平面上机器人的群体形态的演化。在本章节分别对群体聚合形态的基本元件库以及适应度函数进行了介绍,并在本文中设计了一个通用的三维场景下的基因调控网络,使用 XNOR 模块作为骨架来构建处一个含有障碍物以及目标信息的基因调控网络。

在此基础上,本文分别从上层生成和下层控制两个方面对基因调控网络以及运动控制模型进行了分析。并给出了分别从 X、Y、Z 三个维度对浓度场的切分的示意图以及结果图。我们可以发现该模型很好的对在含有障碍物的地图中建立浓度场模型,同时本文利用五个运动控制分量来保证机器人综合考虑后得到最优的运动方向路径。

为了进一步验证该模型的性能,本文使用了 Matlab 和 V-rep 两个仿真平台测试了该三维空间下群体形态自动生成模型在三维场景下的表现。为此本文设计了一个较

为综合的场景作为仿真场景。我们从实验结果的图片中可以看出在加入动力学模型后，该模型仍然适用这类复杂场景。由此可以看出该模型在三维空间中表现良好，也证明了基因调控网络在三维空间中依旧可行。

尽管在 Matlab 和 V-rep 两个仿真平台中证实了基因调控网络在三维空间中有效性，但仍然需要解决计算量大、场景大小较为限定等问题。三维空间下群体形态自动生成框架已经很好的证明了基因调控网络能够很好地适用于三维场景中。下一节，本文将以全局三维基因调控网络模型为基础，通过使用局部地图来实现适用于无人机集群的三维局部分布式基因调控网络模型。

第4章 三维局部分布式基因调控网络模型

本章接着上章提出的三维环境下群体聚合形态自动生成框架,提出一种适用于无人集群的三维局部分布式基因调控网络模型。该三维局部基因调控网络相比于上节提出的基因调控网络,本局部方法更适合实际无人机的应用。因为,在实际应用中,群体机器人所用的摄像头、激光雷达都是不精确的,这些随机误差会导致远处的机器人集群难以捕获目标和障碍物的位姿,同时对于全局坐标系下的三维空间围捕,群体形态会根据目标和障碍物所处的位置实时变化的,而不能提供所有的目标和障碍物会导致该方式难以收敛。为此本文提出了该基于局部坐标系的三维局部分布式基因调控网络模型。

4.1 模型描述及关键技术

在实际的机器人群体中,我们可以发现群体机器人使用的全局定位系统(RTK)、IMU、气压计、里程计等传感器总是会伴随着误差和外界环境所造成的干扰。导致单单通过全局信息生成的模型在效率上以及信息实时性上很难满足群体机器人实机的应用。对于围捕任务来说,群体机器人形成往往会受到环境的影响,而通过局部坐标系的三维局部分布式基因调控网络模型则是能够较好地去实时更新环境对群体机器人的影响。

相较于上一章的三维空间下群体聚合形态自动生成框架而言,从整体框架上就发生了改变,从两层的网络结构拓展为三层网络结构,并通过四点定位的方式来建立合适的局部坐标系,从而不需要考虑整体环境,这样可以使无人集群能够以极低的代价实时运算机器人群体的浓度场。同时在根据浓度场生成部分,本文利用有限状态机建立了适用于局部基因调控网络的基因生成网络模型,并得到合适的浓度场信息。对于机器人群体的运动部分,文章自主设计了一套合适分布式基因调控网络的运动控制策略。该策略从三个维度上简化了运动控制方向的选择,从而实现机器人集群能够在三维环境下快速选择浓度场最低的方向进行运动。

4.1.1 整体模型框架

在群体机器人系统中，一直使用全局地图的方法是不可取的，因为环境中的各种噪声使得群体机器人无法建立起全局地图。进一步说，虽然这样的方法二维场景中的计算损耗可以接受，但是随着维度的扩展，所需要的计算资源会是指数型上涨，这非常不利于我们将算法移植到实机中。为此本文设计了如图 4-1 所示的分布式基因调控网络，该方法在原有的上下两层的 GRN 模型的上方又扩展了一层。首先第一步就是需要群体机器人根据自身的位姿信息建立起局部坐标系，以用于后续的难度场生成；第二步则是根据建立好的含有目标和障碍物位姿的局部地图生成难度场，并给出自适应包围圈；最后一步就是机器人的运动控制，该部分通过六个分量有效地计算出机器人综合运动方向。




图 4-1 基于三维基因调控网络模型的群体模式自动生成方法

4.1.2 三维空间中局部坐标系建立

在群体机器人系统中，每个群体机器人都拥有一定的通信能力，并可以根据摄像头识别出通信范围内其余机器人的距离和方位。如果机器人 B 在机器人 A 的通信范围内，则图中的机器人 A 链接到机器人 B 。如图 4-2 所示，如果一个机器人在邻域内有四个已知距离的局部机器人，则它能够根据包含自身的四个定位点来建立起三维坐标空间。此时其余在通信范围内的群体机器人即可以根据当前建立起的局部坐标系转换自身的坐标系，从而在动态的环境中快速调整浓度信息，从而避免无人机系统发生碰撞。




图 4-2 群体机器人局部坐标系构建

下面将来详细阐述局部坐标系的建立，首先是坐标系中心的选择。这里该算法选择的是距离目标机器人最近机器人 A 作为坐标系的中心，其坐标为 $(0,0,0)$ 。然后，算法会将距离中心机器人最近的邻居机器人记为 B ，而 B 机器人是处于 x 轴上的，且 A 到 B 的方向设为 x 轴的正方向。尤其是， A 利用自身传感器检测到 B 的距离 d_{AB} 后， B 的位置设置为 $(d_{AB}, 0, 0)$ 。之后， y 轴正方向的确立就需要寻找到在 A 和 B 通信范围交集里欧式里德距离数值最小的机器人 C 作为 $x-o-y$ 平面上的点。同时该算法会对该机器人做出限制，该机器人还不应该在 A 和 B 的连接线上，即它不应该在 x 轴上。这样选取后即可以根据三架无人机的位置指定 C 所在的一侧建立 y 轴的正方向。并确定了平面 ABC 。图 4-3 展示了局部坐标系的 x 轴和 y 轴的示意图。在得到平面 ABC 后，通过计算，机器人群体可以得到 y 轴的指向。

值得注意的是，当多个机器人出现在 A 和 B 通信范围交集的区域时，通过式子(4-1)来确定 C 。

$$\min_i (|d_{AB} - d_{iA}| + |d_{AB} - d_{iB}|) \quad (4-1)$$




图 4-3 局部坐标系 x 轴和 y 轴的建立

其中 d_{AB} 和 d_{iA} 分别是 A 到 B 和机器人 i 的距离, d_{iB} 是机器人 i 与 B 之间的距离。此时就可以获得在 d_{AB} 和 d_{iA} 中的通信范围交集的区域了。

由于全方位感知和全局信息的缺乏,不可能通过右手螺旋准则来确定 y 轴的正方向。因此,我们假设 C 在 x 轴的正方向。此外,通过机器人自身传感器信息,可以知道 A 到 B 的距离,记作 d_{AB} ; A 到 C 的距离,记作 d_{CA} ; B 到 C 的距离,记作 d_{CB} 。所以 C 的位置为 $(d_{CA}\cos\alpha, d_{CA}\sqrt{1-\cos^2\alpha}, 0)$, 其中 α 为 AC 与 x 轴的夹角,由式子(4-2)计算出来。

$$\cos\alpha = \frac{d_{AB}^2 + d_{CA}^2 - d_{CB}^2}{2d_{AB}d_{CA}} \quad (4-2)$$

此时, A , B 和 C 的坐标已经确定并分别表示为 (x_A, y_A, z_A) , (x_B, y_B, z_B) , (x_C, y_C, z_C) , 根据该三点坐标可以求出 ABC 所构成平面的平面方程中的 A_1, B_1, C_1, D_1 。

$$A_1 = (y_C - y_A) * (z_C - z_A) - (z_B - z_A) * (y_C - y_A); \quad (4-3)$$

$$B_1 = (x_C - x_A) * (z_B - z_A) - (x_B - x_A) * (z_C - z_A); \quad (4-4)$$

$$C_1 = (x_B - x_A) * (y_C - y_A) - (x_C - x_A) * (y_B - y_A); \quad (4-5)$$

$$D_1 = -(A_1 * x_A + B_1 * y_A + C_1 * z_A) \quad (4-6)$$

到此为止，平面 ABC 、 x 轴与 y 轴已确定，此时要确定 z 轴的方向。同理依据 AB 为 x 轴并取一个不在平面 ABC 上的点 D ，从而确定平面 ABD 的平面方程中的 A_2, B_2, C_2, D_2 。图 4-4 展示了建立局部坐标系 z 轴的建立的示意图。




图 4-4 局部坐标系 z 轴的建立

根据两个面的平面公式以及面与面的夹角公式(4-7)可以求得两个面的夹角 θ 。从而可以确定 z 轴的方向。

$$\cos \theta = \frac{|A_1 A_2 + B_1 B_2 + C_1 C_2|}{\sqrt{A_1^2 + B_1^2 + C_1^2} \sqrt{A_2^2 + B_2^2 + C_2^2}} \quad (4-7)$$

在获取局部三维坐标系后，下一步需要解决的问题是如何通过矩阵变换的方式来实现现在范围内的围捕机器人的坐标转换。在实机场景中，一定范围内的机器人知道自身上一时刻的坐标，利用四点定位来对每个点进行计算存在大量的资源浪费，而利用矩阵变换的方式能够在维持足够精度的同时大幅缩短在坐标系变换所需要的时间。具体步骤如下：

1. 已知原本的坐标系为 x, y, z ，当前时刻的局部坐标系为 x', y', z' 。为此我们随机选取了 DA 两点作为四元数输入的三维变换矩阵。分别对原本坐标系与局部坐标系的参数进行归一化，并得到 $line_{A'D'}$ 与 $line_{AD}$ 。

2. 分两种情况对四元数进行讨论：(1) 如果 $line_{A'D'}$ 与 $line_{AD}$ 相加为 0（即认为他们

反向), 则将四元数设置为 $[0,0,0,0]$; (2) 否则将 $line_{A'D'}$ 与 $line_{AD}$ 叉乘, 并进行归一化得到 u 。之后通过公式(4-8)和(4-9)求出四元数 q 。

$$\varnothing = \frac{\arccos(line_{AD} * line_{AD}^T)}{2} \quad (4-8)$$

$$q = \cos \varnothing * \sin \varnothing * \mu \quad (4-9)$$

并确定旋转矩阵 R 如公式(4-10)所示:

$$R = \begin{bmatrix} 2q_1^2 - 1 + 2q_2^2 & 2(q_2q_3 + q_1q_4) & 2(q_2q_4 - q_1q_3) \\ 2(q_2q_3 - q_1q_4) & 2q_1^2 - 1 + 2q_3^2 & 2(q_3q_4 + q_1q_2) \\ 2(q_2q_4 + q_1q_3) & 2(q_3q_4 - q_1q_2) & 2q_1^2 - 1 + 2q_4^2 \end{bmatrix} \quad (4-10)$$

通过计算所有点与 A 点的差值并得到 $line_{A*}$ 矩阵, 并通过 R 值进行旋转变换。通过公式(4-11)获得在局部坐标系下的对应坐标

$$q = line_{A*} * R \quad (4-11)$$

值得注意的是, 在接下来的仿真验证实验中, 群体中每个机器人的行为都可以用有限状态机模型来描述, 如图 4-5 所示, 从而实现了去中心化的群体机器人系统分布式控制。从 XNOR 模型对应的有限状态机模型图中可以看到, 该有限状态机模型能够有效地包含局部基因调控网络可以遇到的所有情况。从而能够有效的指导机器人群体实现跟踪、围捕等复杂的群体聚合效果。




图 4-5 XNOR 模型对应的有限状态机模型

和三维空间中的全局基因调控网络相似，XNOR 作为唯一的网络组件，用于生成复杂的群体围捕模式。本文针对性的模型进行了对于 GRN 模型，并在原本的三维全局基因调控网络模型的基础上进一步简化了计算复杂度，舍去了拉普拉斯算子等复杂的计算方式，从而更加易于将该模型移植到真实场景中。式(4-12)-(4-17)为三维局部基因调控网络梯度空间的计算形式。

$$T_i = e^{-c\sqrt{(x-\Delta x)^2 + (y-\Delta y)^2 + (z-\Delta z)^2}} \quad (4-12)$$

$$O_j = e^{-c\sqrt{(x-\Delta x)^2 + (y-\Delta y)^2 + (z-\Delta z)^2}} \quad (4-13)$$

$$T = \sum_{i=1}^{N_t} T_i \quad (4-14)$$

$$O = \sum_{j=1}^{N_o} O_j \quad (4-15)$$

$$\frac{dM}{dt} = -M + \text{sig}(1 - T * T, \theta, k) + \text{sig}(O * O, \theta, k) \quad (4-16)$$

$$\text{sig}(x, \theta, k) = \frac{1}{1 + e^{-k(x-\theta)}} \quad (4-17)$$

其中， T_i 代表由第 i 个目标在环境输入下产生的浓度。 O_j 代表由第 j 个障碍物在环境输入下产生的浓度。 T 和 O 为目标与障碍物的浓度总和，从而带入(4-16)得到形态生成的表示形式。 M 为三维局部基因调控网络的形态梯度空间。并在没有障碍物的情况下可以自动转化为式(4-18)。式(4-18)中舍去了障碍物产生的影响，通过参数 θ 和 k 以及输入的目标信息得到形态空间 M 。

$$\frac{dM}{dt} = -M + \text{sig}(1 - T * T, \theta, k) \quad (4-18)$$

为了进一步说明三维基因调控网络中形态梯度空间 M 是如何形成的，我们给出了图 4-6，图中环境内只有一个被夹在两个圆柱障碍物中间的目标。 T 和 O 分别建立的蛋白质浓度场，且离目标和障碍物越远而衰减。算法中设置目标的浓度是较低的(波谷)，而障碍物处的浓度是较高的(波峰)。通过目标和障碍物浓度信息的融合最终在通过障碍物时会出现如图 4-6 中的情况。在(a)时刻，机器人的适宜围捕浓度是保持圆的形式，在(b)时刻是由于刚刚进入两个障碍物之间，其适宜围捕浓度发生挤压，紧接着(c-d)时刻为目标完全进入狭窄通道的情况，此时围捕浓度已经完全发生变化，在(e)时

刻显示了目标快要离开狭窄通道，离开部分的浓度场恢复到初始状态。在(f)时刻，目标完全离开狭窄通道，此时恢复到(a)时刻的状态。




图 4-6 综合浓度场

4.1.3 三维空间中运动控制策略

此外，本文基于全局信息的三维聚合形态的基因调控网络，提出了适用于局部坐标系的运动控制策略。并将其用于引导和控制群体机器人到第二层生成的群体形态上。本文仍然依据雷诺三原则，创建出五个分向量公式(4-19)来指引机器人运动。其运动速度如下：

$$\frac{dP_i}{dt} = \begin{cases} d_i + n_i + z_i + u_i & s_f \geq a \\ b_i & s_f < a \end{cases} \quad (4-19)$$

与第三章描述类似，分量 d_i 表示目标对机器人的排斥分力；分量 n_i 表示机器人与其余围捕机器人的排斥分力；分量 z_i 表示机器人依据浓度场的作用分力；分量 u_i 表示场景密度对该机器人的作用分力；分量 b_i 表示机器人与障碍物的排斥分力； s_f 表示无人机到障碍物的距离， a 为无人机到障碍物的最小安全距离。

我们发现在五个分量计算时，分量 z_i 需要耗费大量的计算时间。为此本文需要寻求一种合适的解决方式来减少浓度场作用分力计算的复杂度。在仿真和实机实验时，我们发现浓度场是缓变的，而群体机器人在短时间内的运动距离基本不会出现极端的

浓度变换,可以默认前方均为可移动区域。因此,针对分量 z_i ,本算法摒弃了传统的机器人浓度场对比方式。在考虑到在局部坐标系下,随着围捕机器人和目标的运动,当前建立的局部浓度场是实时变化的情况。因此,围捕机器人不需要对整个局部浓度场进行分析。可以分别采样上下前后左右三个维度下的情况,来判断三个维度下的分加速度,使围捕模型尽快逼近目标,如图 4-7 所示。



图 4-7 分量 z_i 的选择

如图 4-8 所示,这是该三维局部分布式基因网络的整体模型框架以及上文阐述的对应部分的内容。本文接下来从三个方面来介绍了与三维全局基因调控网络模型框架的差异。第一部分的三点定位方式能够大幅度减少浓度场的计算范围,同时由于不需要直接计算所有的浓度信息,这可以让我们的机器人群体不局限于先验场景,可以通过多种传感器测量,来向集群本身提供有效地浓度地图。这些导致机器人群体可以无边界的探索飞行。而第二部分则涉及到 GRN 模型的 XNOR 模块。在局部分布式基因网络的整体模型框架中,本文通过有限向量机来进一步分析改进 GRN 模型,并优化了 XNOR 的部分浓度计算公式。从而保证机器人群体能够更好的适应三维运动环境,并生成自适应目标的群体聚合形态。第三部分作为最下层的分布式控制,这部分大致和三维全局基因调控网络模型框架类似,但是该算法对机器人依据浓度场的作用分量 z_i 进行了优化。我们通过仿真和实机测试后发现该局部基因调控网络可以利用离散点来代替连续的浓度场力计算,这样可以大幅度减少所需要的计算时间。




图 4-8 整体框架以及对应部分示意图

4.2 实验研究

在上一节中，我们对三维局部基因调控网络模型进行了深入的分析，而在本节，会从仿真平台入手，分析在复杂障碍物情况下机器人群体的性能指标。并逐步分析局部基因调控网络模型在运动时展现的浓度场变化情况以及围捕机器人与三维包围圈的重合性。

4.2.1 三维局部基因调控网络结果分析

首先，本论文用 MATLAB 进行了仿真实验，通过 MATLAB 验证了在含有复杂障碍物的情况下，三维局部基因调控网络模型围捕动态目标的有效性。仿真实验参数如下设置：

- a) 仿真场景大小：25*25*25；

- b) 群体机器人个数：20；目标个数 1 个；
- c) 机器人与机器人之间有一个半径在 4m 左右的通讯方位；
- d) 在复杂场景中,障碍物与障碍物之间至少需要留有 0.25m 左右的可通过空间。




图 4-9 群体机器人三维复杂的环境下围捕动态目标

图 4-9 展示了群体机器人三维复杂的环境下围捕动态目标的整个流程。图 4-9 (a)-(b)展示了当目标穿过由三维障碍物搭建出来的通道时，围捕机器人在接近目标的同时并躲避障碍物。我们可以看到在该部分机器人已经开始进入复杂场景。图 4-9 (c)-(d)展示了目标向下穿过障碍物通道时，围捕机器人以一定的形态包围目标并跟踪目标运动。此时从图 4-9 (a)-(b)的均匀包围变为追随状态，此时可以看到有一部分机器人被复杂障碍物挡住，而绝大多数仍然能够维持在目标周围。图 4-9(e)-(f)展示了目标向穿越障碍物通道后，围捕机器人再次恢复良好包围形态的过程。我们可以看到随着时间的推移，机器人集群基本都可以通过复杂的场景，并最终实现收敛。由图 4-9(a)-(f)整个可见，在三维场景中，三维局部基因调控网络模型可以使围捕机器人在经过多个障碍物后，仍能稳定在目标形态附近，并实现对目标的群体围捕。

紧接着，本文从局部浓度图层面分析了机器人集群的浓度图变化。如图 4-10 所

示, (a)-(f)是 $x-o-z$ 坐标系下的局部浓度图, 这六个图分别对应了上图的(a)-(f)整个过程。我们可以看到 4-10(b)-(c)处处于复杂场景内部, 并发生了浓度场的叠加, 且在图中可以明显看到浓度场叠加而影响的浓度图变化。4-10(d)-(e)处则是上图中不断离开复杂区域的情形, 该处我们可以看到局部浓度图的障碍物区域逐渐变小。直到 4-10(f)处局部浓度地图恢复了 4-10(a)形式, 也可以看到此时的机器人群体已经基本处于目标机器人周围形成良好的围捕。从图 4-10 中可以看到, 通过局部三维基因调控模型, 能够大幅度避免远处的障碍物对基因调控网络的影响, 进而可以极大程度的减少计算复杂度, 并在三维环境下得到良好的运行速率。这为我们将该局部基因调控模型移植到群体机器人上提供了可能性。




图 4-10 $x-o-z$ 坐标系下的局部浓度图

为了尽可能的展现出在该复杂场景后的结果是否稳定, 本文在图 4-11 中展示了三维局部基因调控网络模型与我们无人机集群的重合情况。图 4-11(a)代表了基于局部信息的三维基因调控网络模型形成的三维包围圈, 图 4-11(b)代表了基于局部信息的三维局部基因调控网络模型控制无人集群包围目标后与三维包围圈的重合情况。从图(a)中可以看出, 通过三维局部基因调控网络自动生成的三维包围圈在没有障碍的情况下是一个球形。而图(b)中的围捕机器人可以看到基本落在三维包围圈上, 这代表基因调控模型能够有效地形成良好的包围圈。




图 4-11 三维包围圈以及机器人围捕示意图

4.2.2 三维局部基因调控网络与全局基因调控网络的差异

为了横向对比出三维局部基因调控网络与全局基因调控网络的差异，在相同时间步长下，从围捕机器人与目标的平均距离 D_a 、围捕机器人浓度差 ϕ_s 和围捕机器人包围球面的包围强度 D_s 的变化情况。图 4-12 代表了以图 4-9 为背景得到的三维局部基因调控网络以及三维全局基因调控网络的结果。图 4-12(a)和图 4-12(d)对应了围捕机器人包围球面的包围强度 D_s 的结果。从结果中可以看到这两幅图的起始包围强度基本在 50%左右，而最后的终止包围强度基本稳定在 85%，同时在机器人集群跟随目标进入到复杂障碍物后可以看到明显的包围强度的下降，这也充分反应了机器人集群在图 4-9 中被障碍物排挤到后面的结果。而图 4-12(b)和图 4-12(e)对应了围捕机器人距离变化情况，这一块可以看到由于三维全局基因调控网络能够考虑更多的场景约束，能够对最后的包围结果得到一定的改善，从图中可以看到三维局部基因调控网络的机器人平均距离收敛在距离目标 8 米左右，而三维全局基因调控网络的机器人平均距离收敛在距离目标 6 米左右。而从包围强度这一个结果来看，我们发现，此时的强度基本相差不大，这代表了局部基因调控网络能够更加均匀的围捕目标。图 4-12(c)和图 4-12(f)对应了围捕机器人浓度差的情况，这一块从结果中也可以看到全局三维基因调控网络结果相较于三维局部基因调控网络结果会更加逼近包围

圈，根据分析这一块导致的原因在于基因调控网络损失了一些维度导致的。但是从图 4-12 的上下两行的总体结果来看，平均距离 D_a 、围捕机器人浓度差 ϕ_s 和围捕机器人包围球面的包围强度 D_s 三者的结果在三维局部基因调控网络与三维全局基因调控网络中基本均趋于稳定，且结果的数值基本类似，均收敛在良好的区间内。这代表三维局部基因调控网络与全局基因调控网络在经过复杂场景后均能达到较好的收敛结果。




图 4-12 局部与全局基因调控网络对比

4.3 本章小结

本章主要描述了基于三维全局基因调控网络的基础上改进的三维局部基因调控网络模型。该三维局部基因调控网络从三个层面对全局基因调控网络进行了改动与优化。首先整个网络从两层的网络结构拓展为三层网络结构，并通过四点定位的方式来建立合适的局部坐标系。在基因调控网络生成部分同时在根据浓度场运动部分，本文利用有限状态机建立了适用于局部基因调控网络的基因生成网络模型，此时相较于全局基因调控网络而言，该局部基因调控网络涵盖了更全面的场景，并让基因调控模型更加适合局部基因调控网络模型。对于机器人群体的运动部分，从三个维度上简化了

运动控制方向的选择,从而实现机器人集群能够在三维环境下快速选择浓度场最低的方向进行运动。

在阐述了该模型的改进方面后,本文使用了 **Matlab** 平台对三维 2 局部基因调控网络做了全面的分析。首先,设计了一个较为综合的场景来作为仿真场景。从场景中我们可以看到在经过复杂场景后,机器人群体仍然能够有效地包围。并分别从效果图、浓度场图以及三维包围圈示意图三个图片中显示出该基因调控网络的有效性。

最后本文从平均距离、围捕机器人浓度差和围捕机器人包围球面的包围强度三个方面比较了三维局部基因调控网络和三维全局基因调控网络的性能,并发现两者的性能基本一致。而三维局部基因调控网络能够在未知环境中实现适用于无人机集群的三维局部分布式调控。这也为我们的基因调控网络应用到真实的三维场景打下了良好的基础。

第5章 总结与展望

5.1 本文小结

在现实生活中，群体机器人协作以及群体涌现机理越来越受到学术界的重视，本文在传统的二维基因调控网络的基础上，提出了三维基因调控网络这一网络模型。该框架充分的考虑了在真实场景中机器人集群经常遇到的通信拒止、环境未知、算力有限等情况。使得在三维空间中的群体协作拥有了可能。本文的主要贡献如下：

- 1) 受自然界中蛋白质和基因的表达关系启发，初步提出了一种二阶段的三维全局基因调控网络，该网络的建立为基因调控网络在三维空间中的目标搜索和围捕任务的建立和完成提供了可能性。
- 2) 提出了一种基于三维局部坐标系的基因调控网络框架，该框架改变了传统的两层基因调控网络的结构，从局部坐标系入手，进一步对三维基因调控网络进行优化，并为在实机中分布式部署该基因调控网络提供了可能性。
- 3) 提出了一种三维场景下局部坐标系建立的方式并改进了基因调控网络模型的计算函数，该方式不需要知道全局坐标信息，可以通过有限的机器人群体以及通讯范围，良好的浓度场生成结果，并克服了原浓度场造成的浓度影响过大的问题。该方法的提出让机器人群体不再局限于特定场景，可以在空间中自由探索场景，并形成良好的围捕效果。
- 4) 提出了设计了一套合适分布式基因调控网络的运动控制策略。该策略提出了合理有效的简化运动控制模型简化策略，从三个维度上简化了运动控制方向的选择，从而实现机器人集群能够在三维环境下快速选择浓度场最低的方向并进行控制相应。该策略为真实三维场景下机器人群体提供了有力的保障。
- 5) 受到二维基因调控网络模型评价指标的影响，本文提出了能够有效评价三维空间中群体机器人围捕性能的评价指标，这让本文能够从多种维度来有效衡量在受到三维基因调控网络的影响后，群体机器人系统的结果稳定性以及围

捕有效性。

5.2 未来展望

群体智能机器人作为近年来一门极具重视的一门机器人学分支，国内外的学者在这个方面做出了很多新颖的工作，从原本的二维场景到现在逐步迈入三维场景，这离不开科研工作者的持续努力。本文作为三维基因调控网络的一项创新性工作，虽然有着一些创新，但是仍然存在很多急需解决的问题：

- 1) 机器人群体实机实验平台。目前本文的工作主要是基于 Matlab 和 V-rep 平台，虽然 V-rep 平台就有物理特性，但是仍然无法非常有效的模拟真实场景的各种变化，同时在实机实验平台中信息交互、目标检测的问题目前本文仍然没有考虑到，这些也都将是未来需要解决的问题。因此下一步打算在室内环境中搭建出一套基于动态捕捉仪的小型无人机集群实验平台。
- 2) 更丰富的实验场景。目前设计的场景仍然是较小的仿真场景，并未在庞大真实场景中充分验证该算法的性能，因此在未来的工作中，我们需要选择庞大场景来验证无人机集群在各个场景中的性能以及场景与场景之间的切换的问题。
- 3) 更合理的围捕策略。目前的围捕策略未考虑到多目标情况下围捕机器人的分配问题，这会导致围捕机器人在包围圈分布不均的问题，因此可以在下层的控制中加入分配的问题，并通过编队模型来有效地避免机器人群体跟踪的无序性。

参考文献

- [1] 段海滨, 张祥银, 徐春芳. 仿生智能计算[M]. 北京: 科学出版社, 2011.
- [2] 陈杰, 方浩, 辛斌. 多智能体系统的协同群集运动控制[M]. 北京: 科学出版社, 2017.
- [3] Brambilla M, Ferrante E, Birattari M, et al. Swarm robotics: a review from the swarm engineering perspective[J]. *Swarm Intelligence*, 2013, 7(1): 1-41.
- [4] 赵煦. 走向智能自主的无人机控制技术[J]. *科技导报*, 2017, 35(7).
- [5] 唐强, 张宁, 李浩, 雷志荣. 无人机自主控制系统简述[J]. *测控技术*, 2020, 39(10).
- [6] Cambone S A, Krieg K, Pace P, et al. Unmanned aircraft systems roadmap 2005-2030[J]. *Office of the Secretary of Defense*, 2005, 8: 4-15.
- [7] 陈宗基, 魏金钟, 王英勋, 周锐. 无人机自主控制等级及其系统结构研究[J]. *航空学报*, 2011, 32(6).
- [8] Otto R P. Small unmanned aircraft systems (suas) flight plan: 2016-2036. bridging the gap between tactical and strategic[R]. *Air Force Deputy Chief of Staff Washington DC United States*, 2016.
- [9] Fahey K M, Miller M J. Unmanned Systems Integrated Roadmap 2017-2042[J]. *Department of Defense*, 2017.
- [10] Jarrett R L. Growing up poor: The family experiences of socially mobile youth in low-income African American neighborhoods[J]. *Journal of Adolescent Research*, 1995, 10(1): 111-135.
- [11] 陈静. 多机器人系统编队及实验研究[D]. 北京: 北京理工大学, 2015.
- [12] <http://www.ic-si.org/>
- [13] <https://www.darpa.mil/program/gremlins>
- [14] Vásárhelyi G, Virágh C, Somorjai G, et al. Outdoor flocking and formation flight with autonomous aerial robots[C]//2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. *IEEE*, 2014: 3866-3873.
- [15] Yong E. Autonomous drones flock like birds[J]. *Nature. com*, 2014, 26.
- [16] 王亮. 基于全局视觉的类人型机器人足球系统的设计[D]. 哈尔滨: 哈尔滨工业大学, 2007.

- [17] Duan H, Yang Q, Deng Y, et al. Unmanned aerial systems coordinate target allocation based on wolf behaviors[J]. Science China Information Sciences, 2019, 62(1): 14201.
- [18] 贺光, 赵述龙, 李杰, 王祥科. 智能无人机领域课程思政教育实践[J]. 科教导刊, 2020, (36).
- [19] 段海滨, 申燕凯, 赵彦杰, 范彦铭, 王寅, 牛轶峰, 魏晨, 罗德林. 2019 年无人机热点回眸[J]. 科技导报, 2020, 38(1).
- [20] Dorigo M, Birattari M, Stutzle T. Ant colony optimization[J]. IEEE computational intelligence magazine, 2006, 1(4): 28-39.
- [21] Duan H, Qiao P. Pigeon-inspired optimization: a new swarm intelligence optimizer for air robot path planning[J]. International Journal of Intelligent Computing and Cybernetics, 2014 : 24-37.
- [22] Guo H, Meng Y, Jin Y. A cellular mechanism for multi-robot construction via evolutionary multi-objective optimization of a gene regulatory network[J]. BioSystems, 2009, 98(3): 193-203.
- [23] Oh H, Shirazi A R, Sun C, et al. Bio-inspired self-organizing multi-robot pattern generation: A review[J]. Robotics and Autonomous Systems, 2017, 91: 83-100.
- [24] Li J, Tan Y. A two-stage imitation learning framework for the multi-target search problem in swarm robotics[J]. Neurocomputing, 2019, 334: 249-264.
- [25] Bakhshipour M, Ghadi M J, Namdari F. Swarm robotics search & rescue: A novel artificial intelligence-inspired optimization approach[J]. Applied Soft Computing, 2017, 57: 708-726.
- [26] Levchenko I, Keidar M, Cantrell J, et al. Explore space using swarms of tiny satellites[J]. Nature, 2018, 185–187.
- [27] Bezouska W A, Barnhart D A. Visual sensor selection for satellite swarm cooperative localization[C]//Sensors and Systems for Space Applications XII. International Society for Optics and Photonics, 2019, 11017: 1101705.
- [28] Vásárhelyi G, Virág C, Somorjai G, et al. Optimized flocking of autonomous drones in confined environments[J]. Science Robotics, 2018, 3(20): eaat3536.
- [29] Xie H, Sun M, Fan X, et al. Reconfigurable magnetic microrobot swarm: Multimode transformation, locomotion, and manipulation[J]. Science Robotics, 2019, 4(28): eaav8006.

- [30] Feng Q, Zhang C, Lu J, et al. Source localization in dynamic indoor environments with natural ventilation: An experimental study of a particle swarm optimization-based multi-robot olfaction method[J]. *Building and Environment*, 2019: 106228.
- [31] Amjadi A S, Raoufi M, Turgut A E, et al. Cooperative pollution source localization and cleanup with a bio-inspired swarm robot aggregation[J]. *arXiv preprint arXiv:1907.09585*, 2019.
- [32] Millonas M M. Swarms, phase transitions, and collective intelligence[J]. *arXiv preprint adap-org/9306002*, 1993.
- [33] 段海滨, 李沛. 基于生物群集行为的无人机集群控制[J]. *科教导刊*, 2017, 35(7).
- [34] Mamei M, Vasirani M, Zambonelli F. Experiments of morphogenesis in swarms of simple mobile robots[J]. *Applied Artificial Intelligence*, 2004, 18(9-10): 903-919.
- [35] Kondacs A. Biologically-inspired self-assembly of two-dimensional shapes using global-to-local compilation[C]//*Proceedings of the 18th International Joint Conference on Artificial Intelligence*. Morgan Kaufmann Publishers Inc., 2003: 633-638.
- [36] Jin Y, Meng Y. Morphogenetic robotics: An emerging new field in developmental robotics[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2010, 41(2): 145-160.
- [37] Slavkov I, Carrillo-Zapata D, Carranza N, et al. Morphogenesis in robot swarms[J]. *Science Robotics*, 2018, 3(25): eaau9178.
- [38] Bai L, Eyiurekli M, Breen D E. An emergent system for self-aligning and self-organizing shape primitives[C]//*2008 Second IEEE International Conference on Self-Adaptive and Self-Organizing Systems*. IEEE, 2008: 445-454.
- [39] Cussat-Blanc S, Harrington K, Banzhaf W. Artificial Gene Regulatory Networks—A Review[J]. *Artificial life*, 2019, 24(4): 296-328.
- [40] Ren W. Consensus based formation control strategies for multi-vehicle systems[C]//*2006 American Control Conference*. IEEE, 2006: 6 pp.
- [41] Dadgar M, Jafari S, Hamzeh A. A PSO-based multi-robot cooperation method for target searching in unknown environments[J]. *Neurocomputing*, 2016, 177: 62-74.
- [42] 高杨, 张华飞. 基于领航跟随法和星系动力学的多机器人编队控制[J]. *厦门大学学报(自然版)*, 2013, 52(1): 14—18.
- [43] 潘无为, 姜大鹏, 庞永杰, 等. 人工势场和虚拟结构相结合的多水下机器人编队控制[J]. *兵工学报*, 2017, 38(2): 326—334.

- [44] Sayama H. Robust morphogenesis of robotic swarms [application notes][J]. IEEE Computational Intelligence Magazine, 2010, 5(3): 43-49.
- [45] Belta C, Kumar V. Abstraction and control for groups of robots[J]. IEEE Transactions on robotics, 2004, 20(5): 865-875.
- [46] Cheah C C, Hou S P, Slotine J J E. Region-based shape control for a swarm of robots[J]. Automatica, 2009, 45(10): 2406-2411.
- [47] Jin Y, Guo H, Meng Y. A hierarchical gene regulatory network for adaptive multirobot pattern generation[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(3): 805-816.
- [48] Peng X, Zhang S, Lei X. Multi-target trapping in constrained environments using gene regulatory network-based pattern formation[J]. International Journal of Advanced Robotic Systems, 2016, 13(5): 1729881416670152.
- [49] 王诏君. 多目标进化算法及其在约束优化中的研究[D]. 汕头大学.
- [50] Fedele G, D'Alfonso L. A model for swarm formation with reference tracking[C]//2017 IEEE 56th Annual Conference on Decision and Control (CDC). IEEE, 2017: 381-386.
- [51] 陈铭治, 朱大奇. FMM 与改进 GBNN 模型相结合的多 AUV 实时围捕算法[J]. 控制与决策, 2020, 35(12): 2845-2854.
- [52] Meng Y, Guo H, Jin Y. A morphogenetic approach to flexible and robust shape formation for swarm robotic systems[J]. Robotics and Autonomous Systems, 2013, 61(1): 25-38.
- [53] Braccini M. Applications of biological cell models in robotics[J]. arXiv preprint arXiv:1712.02303, 2017.
- [54] Davidson E, Levin M. Gene regulatory networks[J]. Proceedings of the National Academy of Sciences, 2005, 102(14): 4935-4935.
- [55] Erwin D H, Davidson E H. The evolution of hierarchical gene regulatory networks[J]. Nature Reviews Genetics, 2009, 10(2): 141-148.
- [56] Clyde D E, Corado M S G, Wu X, et al. A self-organizing system of repressor gradients establishes segmental complexity in *Drosophila*[J]. Nature, 2003, 426(6968): 849-853.
- [57] Diambra L, da Fontoura Costa L. Pattern formation in a gene network model with boundary shape dependence[J]. Physical Review E, 2006, 73(3): 031917.

- [58] Taylor T. A genetic regulatory network-inspired real-time controller for a group of underwater robots[C]//Intelligent Autonomous Systems. 2004, 8: 403-412.
- [59] Milo R, Shen-Orr S, Itzkovitz S, et al. Network motifs: simple building blocks of complex networks[J]. Science, 2002, 298(5594): 824-827.
- [60] Bowers P M, Cokus S J, Eisenberg D, et al. Use of logic relationships to decipher protein network organization[J]. Science, 2004, 306(5705): 2246-2249.
- [61] Jin Y, Guo H, Meng Y. A hierarchical gene regulatory network for adaptive multirobot pattern formation[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(3): 805-816.
- [62] Lee L P. The transverse Mercator projection of the entire spheroid[J]. Empire Survey Review, 1962, 16(123): 208-217.

攻读硕士学位期间主要的工作成果

一、发表的学术论文

(一)已见刊或录用论文

- [1] 范衡,马培立,朱贵杰,谢敏冲,陈添善,谢飞,石泽,包卫东,朱晓敏*. 基于三维基因调控网络的智能机器人群体聚合与控制方法.The 18th China Machine Learning Conference (CCML 2021).
- [2] Guijie Zhu, Zhun Fan*, **Peili Ma**, Wenning Huang, Zhihao Ye, Mingwei Huang, Jiangli Li, Zhicheng Jiang, Zhuwei Zhong, and Weiyuan He, (2021, July). Road Crack Acquisition and Analysis System Based on Mobile Robot and Deep Learning. CYBER 2021.
- [3] 范衡,孙福赞,马培立,王诏君,石泽,李文姬,朱贵杰,李恪. 基于共识主动性的群体机器人目标搜索与围捕[J].北京理工大学学报(自然科学版)(2022, 42(2)).
- [4] Peihan Lin, Xiaoming Li, Zhoubin Long, **Peili Ma**, Wenji Li, Guijie Zhu and Zhun Fan*, (2021 July). Pipeline Leak Detection, Localization and Repair. CYBER 2021.
- [5] 范衡,李晓明,郭谊,王诏君,李文姬,林培涵,马培立,朱贵杰,李恪,李兵,朱晓敏,包卫东,辛斌. 基于在线调整的群体聚合形态动态生成方法[J]. 流体测量与控制. 2021: 1-12.

二、发表专利

- [1] 一种裂缝检测方法及系统. 发明人: 朱贵杰; 范衡; 陈添善; 谢飞; 谢敏冲; 马培立 申请号: CN202110483642.1 公开号: CN113160202A
- [2] 一种基于三维基因调控网络的智能机器人群体控制方法. 发明人: 范衡; 马培立; 谢飞; 陈添善; 谢敏冲; 朱贵杰; 石泽; 王诏君 申请号: CN202110481878.1 公开号: CN113172626A
- [3] 一种带压堵漏机器人自主漏点定位方法. 发明人: 范衡; 李晓明; 龙周彬; 林培涵; 马培立; 韦家弘; 姜志成; 何伟源; 钟铸威 申请号: CN202110205771.4 公开号: CN113001559A
- [4] 一种基于U型编码解码器神经网络的道路裂缝检测方法及系统. 发明人: 朱贵杰; 黄铭威; 马培立; 范衡; 李晓明; 林培涵; 韦家弘; 黄文宁; 叶志豪; 李建立 申请号: CN202110102284.5 公开号: CN112785578A
- [5] 一种可分离式陆空两栖协同机器人的控制方法及系统. 发明人: 范衡; 朱贵杰;

- 马培立**；唐紫樑；陈锦华；万琪；李建立；黄铭威；姜志成 申请号：CN202110103227.9 公开号：CN112882477A
- [6] 一种基于人群密度估计的指引机器人方法及系统. 发明人：**马培立**；范衡；李晓明；林培涵；朱贵杰 申请号：CN202011381811.2 公开号：CN112731919A
- [7] 一种带压堵漏机器人的漏点定位自主控制方法及系统. 发明人：范衡；**马培立**；林培涵；李晓明；朱贵杰；王诏君 申请号：CN202011374018.X 公开号：CN112571425A
- [8] 一种群体机器人的多目标搜索与围捕控制方法及系统. 发明人：范衡；林培涵；**马培立**；王琛；宁为博；李晓明；王诏君；李文姬 申请号：CN202011373975.0 公开号：CN112684700A
- [9] 一种基于群体机器人的目标围捕控制方法及系统. 发明人：范衡；**马培立**；王诏君；石泽；蔡堉伟；李晓明；林培涵；李文姬 申请号：CN202011376837.8 公开号：CN112527020A
- [10] 一种行人轨迹预测和跟随的机器人方法及系统. 发明人：范衡；**马培立**；朱贵杰；林培涵；李晓明 申请号：CN202010388347.3 公开号：CN111708042A
- [11] 一种混合注意力机制的眼底图像视网膜血管分割方法. 发明人：**马培立**；朱贵杰；范衡；李晓明；林培涵 申请号：CN202011048427.0 公开号：CN112132817A

致谢

时光如梭，转眼间已经即将成为一名汕头大学研究生毕业生。此时的校园因为曾经的努力拼搏而留下了许多美好的回忆变得不一样了，这三年我们经历了疫情，也度过了一段段不平凡的时光。回望过往，我收获了很多。这当中包括了很多曾经没有接触过的学问、一系列良好的制作思考风格，还有很多非常要好的朋友以及师生情，这些都是我一辈子珍藏的回忆。这些都得益于我的母校、我的导师、我的同学，是他们让我度过了三年充实而快乐时光。从连夜调试机器到论文撰写，这里留下了我人生中三年的时光。临别之际总是万般不舍，但更多的是心怀感激以及满怀记忆。

首先我要感谢我的导师，尊敬的范衡教授。从本文的选题到整个论文的撰写完毕，都得到了范衡教授的悉心指导与帮助。范衡教授作为是群体智能和进化计算领域的专家，让我从单独的机器人控制的局限眼光中跳出来，看到了更广阔的群体机器人领域。学术上您是一位学识渊博、治学严谨、视野开拓的学者，让我改掉了我本科养成的思路不清晰的坏习惯，让我能够以更清晰、更敏锐的思维来面对接下来的生活和工作。是您在学业上对我进行了悉心的指导，也是您引领我走进神圣的科研殿堂。在研究生期间的成长，让我养成了科学的思维习惯。工作中您求真务实，踏实勤奋的作风深深地感染了我，我也不断向您学习，不断地沉下心来期望做出一些能够有利于社会的工作。您不仅是一位良师，同时在生活中也是一位乐于关心倾听的益友。您常常在为同学们指导人生的方向，从未来的人生决策到工作态度，为我们树立了榜样，也为我们指明了方向，这让我受益匪浅。我这三年的时光充满了范衡老师的悉心教导，这也是我能快速的成长的关键原因。在此我由衷地感谢我的导师范衡老师。

其次，我要感谢汕头大学人工智能与机器人实验室的李文姬师兄、朱贵杰师兄、游煜根师兄、王诏君师兄、陈文钊师兄等师兄，谢谢你们在生活中和科研上对我的悉心指导。犹记得每当我项目中遇到困难寻求帮助时，你们总能挺身而出，为我解决问题。让我在机器人领域继续深耕。当我生病时，你们的带我去医院，对我的悉心照料。另外我想感谢林培涵、李晓明、龙周彬、黄文宁、韦嘉宏等我们实验室的同学。在学术上我们相互帮助，共同成长。没有你们我自己很难有这么快乐时光，一次次思维的碰撞，项目的完成都少不了各位的帮助。我还要感谢石泽、蔡堉伟、黄华兴、宁为博等师弟，感谢你们与我一路同行，也怀念那些一起熬夜肝项目的日子，愿你们在未来都更进一步，拥有一个更美好的明天。此外，我还想感谢谢敏冲、陈善添、谢飞、叶志豪、李建立、钟涛威等本科师弟，感谢你们和我一起做项目写文档，让我们的成果能够快速产出，在收获知识的同时也带来了很多的快乐和满足。

最后，我要感谢我的家人和朋友。是你们这么多年对我无条件的信任与支持，这

是我一直努力向前的动力，也正是因为你们对我的关爱和鼓励，让我能够毫无后顾之忧地完成我的硕士学业。所以在这里对于我的家人，我由衷地谢谢你们。愿自己在未来做的更加好。

作者：马培立

2022 年 03 月 10 日