

基于人工免疫的无人机航迹规划

汪羽龙, 辜方清*

广东工业大学数学与统计学院, 广东 广州

收稿日期: 2024年12月20日; 录用日期: 2025年1月16日; 发布日期: 2025年1月24日

摘要

针对传统遗传算法在无人机航迹规划问题中的效率低下和结果不一致性, 本研究提出了一种创新的基于人工免疫的遗传算法(genetic algorithm based on artificial immunity, AIGA)。AIGA通过建立动态疫苗库, 根据迭代次数动态调整, 增强了对不良解的识别与淘汰, 有效提升了路径规划的质量和效率。本算法与多种进化算法在路径优化和无人机航迹规划问题上进行了比较, 实验结果证明, AIGA能为无人机生成安全且经济的飞行路径, 并在路径优化问题上显示出与其他启发式算法相比的显著优势, 显示出广阔的应用潜力。

关键词

人工免疫, 遗传算法, 无人机航迹规划, 路径优化

UAV Path Planning Based on Artificial Immunity

Yulong Wang, Fangqing Gu*

School of Mathematics and Statistics, Guangdong University of Technology, Guangzhou Guangdong

Received: Dec. 20th, 2024; accepted: Jan. 16th, 2025; published: Jan. 24th, 2025

Abstract

To address the inefficiencies and inconsistencies associated with traditional genetic algorithms in UAV path planning, this study introduces an innovative approach known as the Genetic Algorithm Based on Artificial Immunity (AIGA). AIGA enhances the identification and elimination of inferior solutions by employing a dynamic vaccine repository that adjusts according to the number of

*通讯作者。

iterations, thereby significantly improving the quality and efficiency of path planning. Comparative experiments with various evolutionary algorithms on path optimization and UAV path planning problems have demonstrated that AIGA can generate safe and economical flight paths for UAVs. It shows a distinct advantage over other heuristic algorithms in path optimization issues, indicating its broad potential for application.

Keywords

Artificial Immunity, Genetic Algorithm, UAV Path Planning, Path Optimization

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着无人飞行器(UAV)在现代工作生活中的广泛应用,例如军事侦察、物流配送、环境监测等领域均会使用无人机进行工作。因此如何高效、安全地规划其飞行路径已成为一个重要课题。在复杂的现实环境中,无人机需要避开干扰区域,同时考虑飞行效率和任务需求[1]。

传统的路径规划方法往往难以同时满足复杂环境的要求。为了应对日益增加的复杂性,研究人员逐渐将兴趣从确定性算法转移开。为了避免低效的枚举过程,近年来开发并研究了智能算法解决无人机航迹规划问题,如遗传算法(GA) [2]、差分进化算法(DE) [3]、粒子群优化算法(PSO) [4]以及人工蜂群算法(ABC) [5]等。而在采用这些算法之前,需要建立适当的数学模型,将路径规划任务转化为数值优化问题。在以往的研究中,研究人员已经考虑到了威胁源域内外的差异,并建立了基于概率密度模型计算的成本模型[6]-[9]。但是,我们发现无人机的航迹规划问题需要考虑复杂的现实环境。然而以往的无人机航迹规划研究往往未能充分利用现有的环境信息以及种群迭代过程中产生的有益信息[10]。

为了能充分利用现有的环境信息以及种群迭代过程中产生的有益信息,本研究提出一种新的无人机航迹规划算法——基于人工免疫的遗传算法(AIGA)。AIGA 算法的核心优势在于其能够模拟生物免疫系统的负选择机制[11],通过构建动态疫苗库,有效识别并利用优良基因,从而加速种群向全局最优解的进化[12]。

本研究通过一系列精心设计的实验,对比分析了 AIGA 算法在不同维度、不同威胁环境下的性能表现[13]。实验结果表明,AIGA 算法不仅在路径优化测试问题上优于其他启发式算法,而且在实际应用场景中,无论是横向、纵向还是斜向地图,以及不同雷达数量条件下,均能生成安全、经济的飞行路径,显示出卓越的适应性和鲁棒性。AIGA 在运行过程中,通过从种群中搜索减小路径长度的边,构建疫苗库,引导父代路径产生更优解。随着种群的进化,疫苗库同步更新,推动种群个体逐步接近最优解。实验结果证明,该改进算法能够有效地为无人机生成安全、经济的飞行路径,在路径优化测试问题上也与其他启发式算法有着显著优势,具有良好的应用前景。

本文在引言部分首先介绍了无人机航迹规划的研究背景和现状,然后分析了目前研究的不足,最后阐述了 AIGA 算法的理论基础和核心优势。接下来,详细描述算法的实现过程,包括数学模型的建立、优良疫苗的选择、动态疫苗库的构建和种群进化策略。文章将通过一系列实验,对比分析 AIGA 算法在不同维度、不同威胁环境下的性能表现。最后,根据实验结果,总结 AIGA 算法的优势、不足及应用前景。

2. 模型建立

2.1. 假设条件

为更好地对问题进行研究, 便于模型的建立和求解, 结合实际情况对问题提出以下假设:

(1) 环境稳定性: 真实飞行环境是复杂且多变的, 存在多种自然和人工威胁, 假设威胁源以及威胁半径在飞行过程中保持不变[14]。

(2) 速度恒定: 假设在规划路径时, 无人机保持恒定的飞行速度, 因此燃油消耗与飞行路径的总长度成正比。

(3) 高度恒定: 假设无人机飞行的高度不变。

2.2. 无人机航迹规划模型

无人机航迹规划问题是一类特殊的路径规划问题, 其成本函数如下:

$$C_{\text{total cost}} = \gamma \cdot T + (1 - \gamma)D \quad (1)$$

其中, 第一个部分 T 代表路径的威胁函数, D 代表路径长度。 γ 代表重要程度, 本文均取 $\gamma = 0.5$, 代表路径长度和威胁风险在总成本中占有相同的比重[15]。

第一部分 T 定义为:

$$C_{\text{threat influence}} = \exp\left(-\frac{\sum_{i=1}^n \|d_i\|}{\delta}\right) \quad (2)$$

$C_{\text{threat influence}}$ 是基于概率密度模型计算的成本, 表示无人机在飞行路径上遭受威胁的风险。它考虑了无人机与各个威胁中心的距离, 以及这些威胁的潜在影响。其中 n 是该区域内威胁源的总数。 d_i 是路径上的点到第 i 个威胁中心的距离 δ 是控制概率密度函数形状的参数。

第二部分 D 定义为:

$$D = \frac{\int d_j}{\|ST\|} \cdot (1 - \gamma) \quad (3)$$

D 是经过标准化后的路径函数, 表示无人机的飞行航机路径得分。 d_j 表示第 j 条路径段的长度, $\|ST\|$ 代表起始点到终点连线的距离。

3. AIGA 算法

3.1. AIGA 算法介绍

遗传算法(GA)通过选择操作保留适应度较高的染色体, 并通过交叉与变异操作来生成具有更高适应度的染色体。然而, GA 的随机交叉与变异算子导致种群进化的不确定性, 这影响了算法的寻优速度[16][17]。此外, GA 的计算结果往往缺乏一致性, 与最优解存在较大偏差。为了获得满意解, GA 常需设置大规模种群和多轮迭代, 但频繁的交叉与变异操作未必能产生更优染色体, 从而消耗大量计算资源[18]。

为了提高 GA 的搜索效率, 本研究基于人工免疫算法提出了优良疫苗(Excellent vaccines)和疫苗库(Vaccine data-base)的概念, 并设计了基于人工免疫的遗传算法(AIGA)去解决无人机航迹规划问题。

优良疫苗: 在给定的优化问题中, 代表最优解的染色体由多个紧密相关的染色体片段组成, 其中能够提升个体适应度的染色体片段被称为优良疫苗。

疫苗库: 若干优良疫苗构成一个疫苗库。

针对无人机航迹规划问题, 其最优解是一系列路径段的集合。AIGA 在运行过程中, 从种群中筛选出优秀个体作为优良疫苗, 并构建疫苗库。利用这些疫苗改造个体, 可以生成具有更高适应度的新个体。通过多次迭代, AIGA 能够最终收敛至最优解或近似最优解。

3.2. 实数编码

在无人飞行器(UAV)的路径规划中, 编码方案的选择对于优化算法的性能至关重要。实数编码作为一种直观且易于操作的编码策略, 在遗传算法解决 UAV 航迹规划的问题中得到了广泛应用。本节将详细介绍实数编码的概念及其在 UAV 路径规划中的应用。

实数编码是一种使用实数来表示解空间中点的编码方式。在无人飞行器(UAV)路径规划问题中, 每个解决方案可被视为一个多维实数向量。该向量的每个维度代表路径上特定的参数, 例如航点坐标、飞行高度或所需时间等。实数编码的直接性和连续性使其在处理连续优化问题时尤为有效。

在 UAV 的路径规划问题中, 实数编码允许算法直接在地理空间中搜索最优路径。例如, 一条路径可以表示为一个实数向量如公式(4)。

$$p = [x_1, y_1, x_2, y_2, \dots, x_N, y_N] \quad (4)$$

其中 (x_i, y_i) 是第 i 个航点的坐标。这种表示方法不仅简洁, 而且便于遗传算法中的交叉和变异操作。

3.3. 初始化种群和疫苗库

采用随机方式生成初始种群:

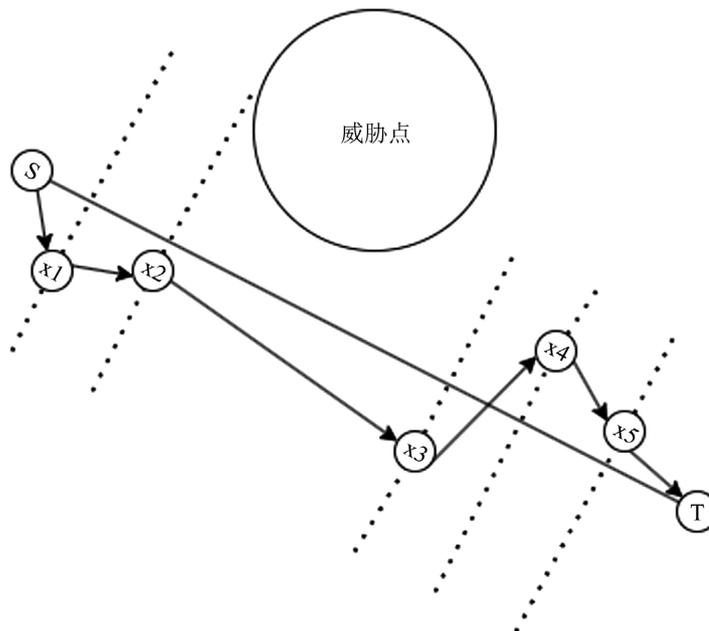


Figure 1. Path segmentation schematic chart

图 1. 航迹分段示意图

对于给定上下限的无人机航迹规划问题, 如图 1 所示, 需要获得一条连接起始点和终点的路径。首先, 画出连接起始点和终点的线段 ST 。然后, 这条线段 ST 被 D 条垂直线等分成 $(D + 1)$ 份, 这些线在每

个分段点与 ST 相交。这些 D 条线被视为新的坐标轴, 在这些轴上, 采用随机采样的方式生成初始航点, 重复上述操作, 直到生成个体数量达到种群规模。

初始化疫苗库:

对于规模为 D 的无人机航迹规划问题而言, 考虑到组成最优解的路径上的航点往往都会远离威胁点, 因此根据初始疫苗库中的疫苗由给定上下限的非威胁源内的其他区间内的任意点构成。

3.4. 疫苗库的更新规则

在 AIGA 算法中, 通过评估航迹种群来挑选出优良疫苗, 并以此构建疫苗库, 目的是推动种群向最优解方向进化。我们采用以下两种策略来识别新的优良疫苗:

a) 使用启发式方法对个体进行改进, 并计算其适应度, 将能显著提升个体适应度的航点区间识别为优良疫苗。

b) 将种群中频繁出现的航迹段视为优良疫苗, 这些高频航迹段在进化过程中保持稳定, 对种群生存具有积极作用。

优良疫苗的生成对 AIGA 至关重要。通常, 较短的路径段有助于缩短总航迹长度。方法 a) 能够产生这类路径段, 而初始疫苗库中也应包含这样的边。此外, 如果一条路径段普遍存在于多个近优解中, 那么它很可能是最优解的一部分, 这种可能性与问题的规模无关。在 AIGA 的迭代过程中, 将逐步生成越来越接近最优解的航迹。

基于这些理论, 我们提出了优良疫苗的生成方法。AIGA 的不同阶段将采用不同的优良疫苗生成策略。在计算初期, 由于种群内航迹的质量参差不齐, 利用初始疫苗库中的疫苗可以有效地提升航迹的适应度。随着种群的进化, 仅依靠初始疫苗库难以继续提高种群适应度。这时, 需要向疫苗库中添加更优质的优良疫苗, 结合方法 a) 和 b) 来生成, 以充分利用疫苗库的引导作用。接下来, 我们将介绍算法运行中优良疫苗评价的标准。

在 AIGA 算法中, 设定最大迭代次数为 MCN , 种群数量为 N_P 。AIGA 的执行过程被 MCN 分为三个阶段, 每个阶段对优良疫苗的评估遵循公式(5)。迭代次数变量 $limit$ 根据公式(5)确定, 只有满足该公式的航点才会被认定为优良疫苗, 以便更新疫苗库。在算法的不同阶段, 如果一条边被视为优良疫苗, 该边则必须能使种群中适应度提升的航迹数量超过 $limit$ 函数的设定值。具体如下:

在迭代初期, 当 $iter < \frac{MCN}{4}$ 时, 一个优良疫苗至少能提高种群中 $\frac{N_P - iter}{2}$ 个航迹的适应度值。

在迭代中期, 当 $iter$ 属于 $\frac{MCN}{5} \leq iter \leq \frac{MCN}{2}$ 时, 一个优良疫苗至少能提高种群中 5 条航迹的适应度值。

在迭代后期, 当 $iter$ 属于 $iter > \frac{MCN}{2}$ 时, 一个优良疫苗确保能够提高 1 条航迹的适应度值。 $limit$ 函数值随着迭代次数的增加而逐渐降低。在算法迭代次数完成一半时, 算法进入第三阶段。此时, 种群中的每条航迹都已经被优良疫苗改进多次, 具备较高的适应度, 任何一条航迹变优秀, 都利于找到最优解, 因此将 $limit$ 函数值设定为 1。

$$limit = \begin{cases} \frac{N_P - iter}{2} & iter < \frac{MCN}{4} \\ 5 & \frac{MCN}{4} \leq iter \leq \frac{MCN}{2} \\ 1 & iter > \frac{MCN}{2} \end{cases} \quad (5)$$

3.5. 基于定向启发式交叉的方法生成优良疫苗

在遗传算法的进化过程中, 交叉操作是探索解空间和生成新解的关键步骤。定向启发式交叉(DHX)是一种先进的交叉技术, 它利用启发式信息来指导交叉过程, 从而提高算法的搜索效率和解的质量。

DHX 的核心思想是在交叉过程中不仅考虑父代解的特征, 还融入了问题特定的启发式知识。这种方法通常适用于那些具有明确邻域结构或可以应用贪心策略的优化问题。

在无人机航迹规划问题中, 基于定向启发式交叉的方法生成新的航迹并生成新的优良疫苗的方式如公式(6):

$$X_i^j = X_i^j + rand(0,1) \cdot (V - X_i^j) \quad (6)$$

$$j = 1, 2, \dots, D; i = 1, 2, \dots, N$$

其中 X_i^j 为种群中第 i 条航迹, 第 j 个航点, V 为从疫苗库中抽取的优良疫苗的航点坐标产生新优良疫苗的具体步骤如下:

- a) 从疫苗库随机选择一个优良疫苗, 即相邻的两个航点的坐标。
- b) 选择种群中相应的相邻航点。
- c) 根据公式(6)产生新的航迹。
- d) 根据公式(5)判断是否满足优良疫苗的评价标准。
- e) 若满足优良疫苗的评价标准, 则更新疫苗库中的优良疫苗。

3.6. 基于高频航迹段的方法生成优良疫苗

经过多轮迭代后, 种群中的多数航迹已趋近于最优解, 传统方法难以识别更优质的优良疫苗。为推动种群个体继续进化至最优解, 本文引入优良疫苗的竞争机制, 旨在从当前种群中培育出更优秀的疫苗并构建疫苗库。

对于每一代种群, 我们计算每条航迹段在种群中的包含次数, 这一数值反映了航迹段的出现频率。将出现频率最高的前 K 条航迹段选为优良疫苗并加入疫苗库, 其中 K 的值根据实际问题的规模来确定。

高频航迹段因其在多次迭代中保持稳定而未被淘汰, 有助于培育更优秀的航迹种群, 从而增强算法的全局搜索能力。在获得高频航迹段后, 依然按照公式(1)的规则生成下一代种群。但在选择优良疫苗时, 不再单纯基于提升个体适应度值, 而是通过统计每条航迹段在种群中的出现频率来确定。

产生新优良疫苗的具体步骤如下:

- a) 从疫苗库随机选择一个高频航迹段的优良疫苗, 即相邻的两个航点的坐标。
- b) 选择种群中相应的相邻航点。
- c) 根据公式(6)产生新的航迹。
- d) 更新种群。
- e) 统计更新后的种群中的高频航迹段, 并将前 K 个高频航迹段作为优良疫苗, 更新疫苗库。

3.7. 算法步骤

算法的具体流程如 AIGA 算法所示, 首先, 我们初始化种群大小为 N , 种群为 X , 迭代数的最大值为 MCN 。然后生成初始疫苗库, 并初始化种群。

在迭代初期, 当 $iter < \frac{MCN}{4}$ 时, 利用初始疫苗库中的优良疫苗对种群进行进化, 同时记录当前找到的最佳解。

在迭代中期, 当 $\frac{MCN}{4} \leq iter \leq \frac{MCN}{2}$ 时, 利用初始疫苗库中的优良疫苗对种群进行进化, 同时记录当前找到的最佳解。并利用基于定向启发式交叉的方法生成优良疫苗, 然后更新疫苗库。

在迭代后期, 当 $iter > \frac{MCN}{2}$ 时, 利用初始疫苗库中的优良疫苗对种群进行进化, 同时记录当前找到的最佳解。并利用基于高频航迹段的方法生成优良疫苗, 然后更新疫苗库。

AIGA 算法

输入: 迭代数最大值 MCN , 种群规模 N 和种群 X 。

输出: 历史最优路径 X_{best} 。

a) 初始化疫苗库, 并初始化种群

b) while $iter \leq MCN/4$ do

1 for $i \leq N$ do

- i. 从初始疫苗库中选择疫苗 V ;
- ii. 根据所选择的疫苗与个体 x_i , 利用公式(6)生成新的个体;
- iii. 检查新个体是否在边界内并进行调整;
- iv. 如果新的个体更好, 则更新个体 x_i 。

2 记录当前找到的最佳解 X_{best}

3 增加迭代次数 $iter$

c) while $iter \leq MCN/2$ do

1 for $i \leq N$ do

- i. 提取种群中的优良个体更新疫苗库;
- ii. 从疫苗库中选择疫苗 V ;
- iii. 根据所选择的疫苗与个体 x_i , 利用公式(6)生成新的个体;
- iv. 检查新个体是否在边界内并进行调整;
- v. 如果新的个体更好, 则更新个体 x_i ;
- vi. 更新疫苗库。

2 记录当前找到的最佳解 X_{best}

3 增加迭代次数 $iter$

d) while $iter \leq MCN$ do

1 for $i \leq N$ do

- i. 计算当前种群中的高频疫苗更新疫苗库;
- ii. 从疫苗库中选择疫苗 V ;
- iii. 根据所选择的疫苗与个体 x_i , 利用公式(6)生成新的个体;
- iv. 检查新个体是否在边界内并进行调整;
- v. 如果新的个体更好, 则更新个体 x_i ;
- vi. 更新疫苗库。

2 记录当前找到的最佳解 X_{best}

3 增加迭代次数 $iter$

e) end while

AIGA 的算法流程如图 2 所示, 实现步骤如下:

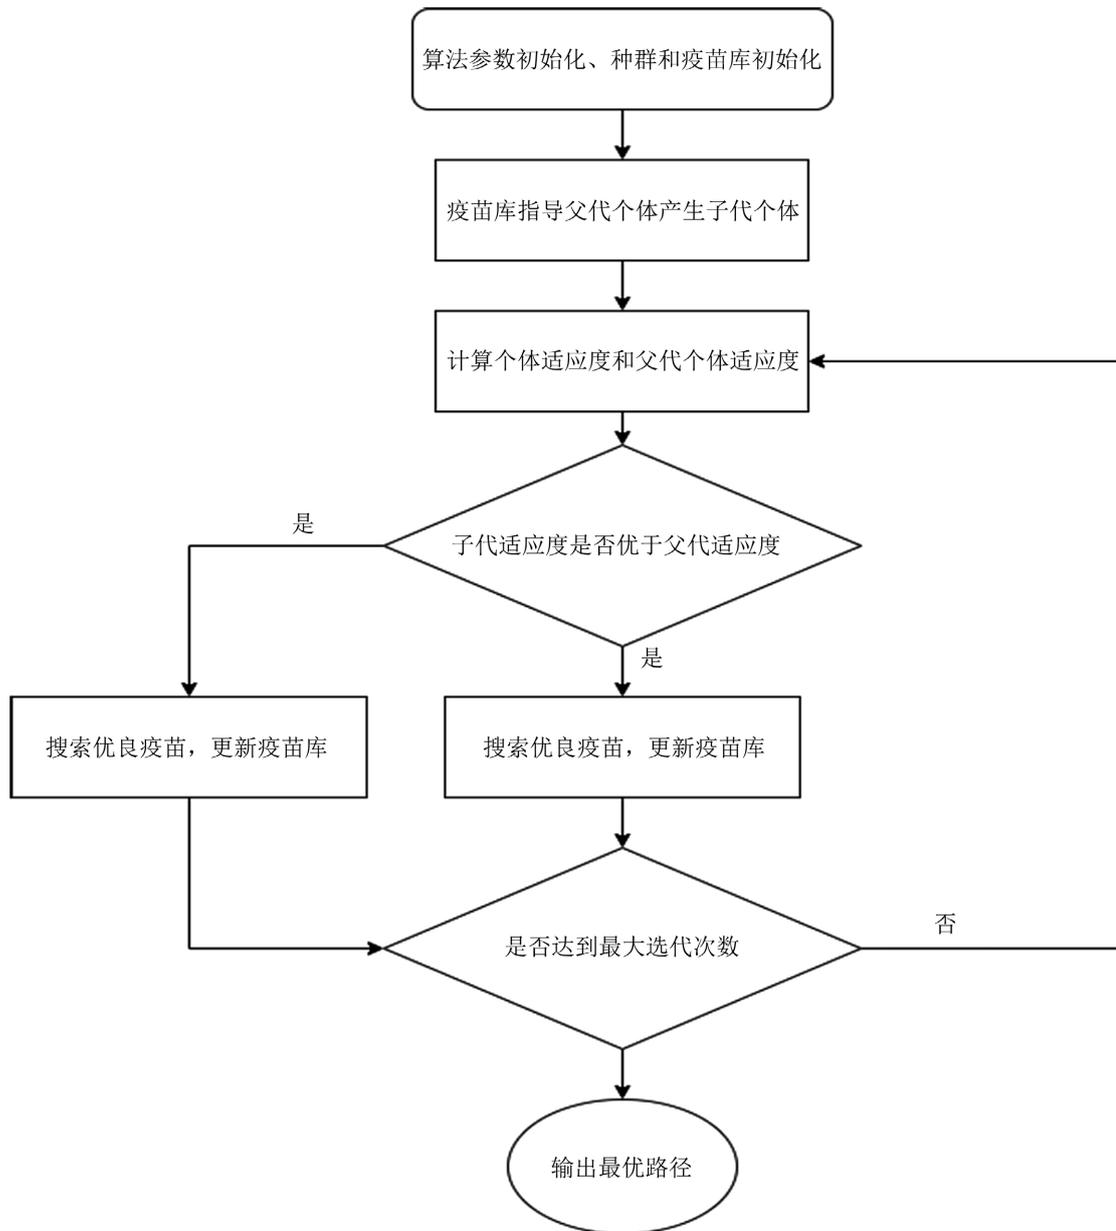


Figure 2. Flow chart of AIGA algorithm
图 2. AIGA 算法流程图

4. 实验与结果分析

4.1. 对比算法

我们将所提出的 AIGA 算法与 ABC、PSO 等启发性算法进行比较，以研究所提出算法的性能。编写 AIGA 程序研究该算法在具体案例上的应用，使用了 9 个模拟无人机航迹规划案例分析，分析计算结果并与以往同类算法的性能进行比较。对每个问题计算 10 次，通过对比计算结果验证算法的性能。

4.2. 参数定义

为研究该算法在具体案例上的应用，使用了 3 个模拟无人机航迹规划案例分析，分析计算结果并与

以往同类算法的性能进行比较。对每个问题计算 10 次, 通过对比计算结果验证算法的性能。

在无人机航迹规划的研究中, AIGA 算法涉及多个参数设置, 包括种群规模 NP 、初始疫苗库容量 NG 、高频路径段数量 NF 、从疫苗库中随机选取优良疫苗的数量 k 、算法的最大迭代次数 MCN 、问题的规模 D , 以及优良疫苗的选择标准 $limit$ 。具体参数设置参照表 1。

在不同规模的航迹规划案例中, AIGA 算法的参数配置如下: 种群规模设定为 NP , 初始疫苗库大小为 NG , 高频路径段数量为 NF , 每次从疫苗库中随机选取优良疫苗的数量为 k , 算法的最大迭代次数为 MCN 。这些设置旨在确保算法能在合理的时间内提供满意的解决方案。此外, 为了缩短计算时间, 在每次迭代中, 根据种群规模 n 的增加, 相应增加从疫苗库中随机选取的优良疫苗数量 k , 以促进种群的进化。具体的参数配置详见表 2。

Table 1. Parameter settings of AIGA

表 1. AIGA 参数设置

参数名称	符号	描述	取值
种群数目	NP	每一轮迭代的航迹总数	40
最大迭代次数	MCN	算法运行的最大迭代次数	100
限制	$limit$	优良疫苗的评价指标	如公式(9)
问题维度	D	航迹点数目	30~40
疫苗库规模	NG	疫苗库中储存优良疫苗的数量	$4n$
高频航迹段数目	NF	高频航迹段的数目	30
优良疫苗数目	K	每一轮优良疫苗的选择个数	1
概率密度函数参数	δ	控制概率密度函数形状	10
重要程度系数	γ	控制路径长度和威胁风险的比重	0.5

Table 2. Parameter settings of maps

表 2. 地图参数设置

N	NP	NG	NF	K	MCN
$N \leq 10$	50	$4n$	30	1~2	100
$10 \leq N < 20$	100	$5n \sim 6n$	50	3	100
$20 \leq N < 30$	100	$7n \sim 10n$	50~100	3~5	200
$N \geq 30$	200	$10n \sim 12n$	100	5~7	300

4.3. 参数敏感性分析

参数 δ 控制着概率密度函数的形状, 进而影响对无人机飞行路径上威胁风险的评估。参数 D 代表问题维度, 通常与路径的复杂性和搜索空间的大小相关。通过改变这两个参数的值, 我们评估了它们对算法性能的敏感度。我们将通过一系列实验, 系统地改变参数 δ 和 D 的值, 记录算法的收敛曲线。实验将在 MAP 1 上, 取不同的 δ 值($\delta = 3, \delta = 5, \delta = 10$)和 D 值(如 $D = 10, D = 20, D = 30$), 利用 AIGA 算法, 进行十轮计算并取平均值作为最终结果。

图 3 展示了不同 δ 值对算法收敛性能的影响。随着 δ 值的增加, 我们观察到收敛曲线的变化。较小的 δ 值可能导致算法过于敏感与威胁, 从而生成过于保守的路径, 这反映在收敛速度较慢或最终解的次优性上。在 $\delta=5$ 时, 此时收敛曲线显示出最佳性能, 表明该值允许算法在风险规避和路径效率之间取得平衡。此时的解具有最低的成本, 同时保持了较快的收敛速度。如果 δ 值继续增加, 会导致算法对威胁源的容忍度增加, 导致对威胁源的识别不足, 从而在收敛曲线上表现为解的质量下降。

图 4 展示了问题维度 D 对算法收敛性能的影响, D 代表路径分段的数量。在 $D=30$ 时, 收敛曲线达到最佳状态, 但与 $D=20$ 时的搜索效率提升不明显。这可能是因为搜索空间的扩大增加了寻找全局最优解的难度, 因此寻找合适的问题维度数目对于最优路径的求解十分重要。

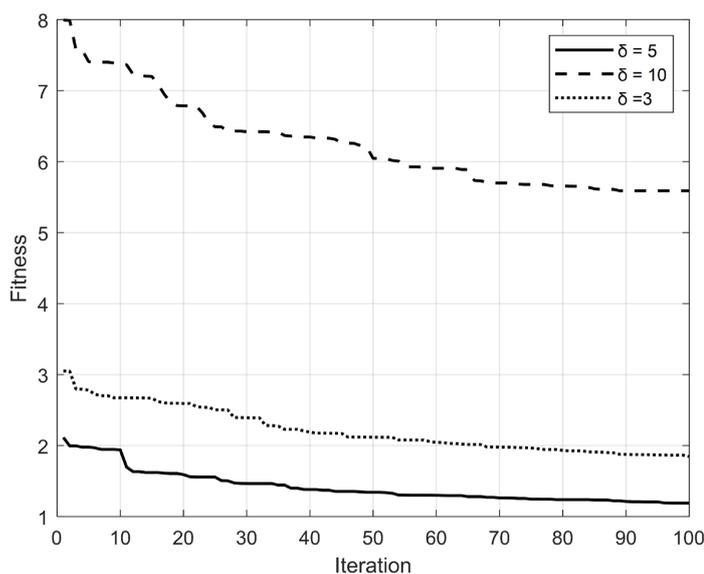


Figure 3. Convergence curve variations with different δ values

图 3. 不同 δ 值下的收敛曲线变化图

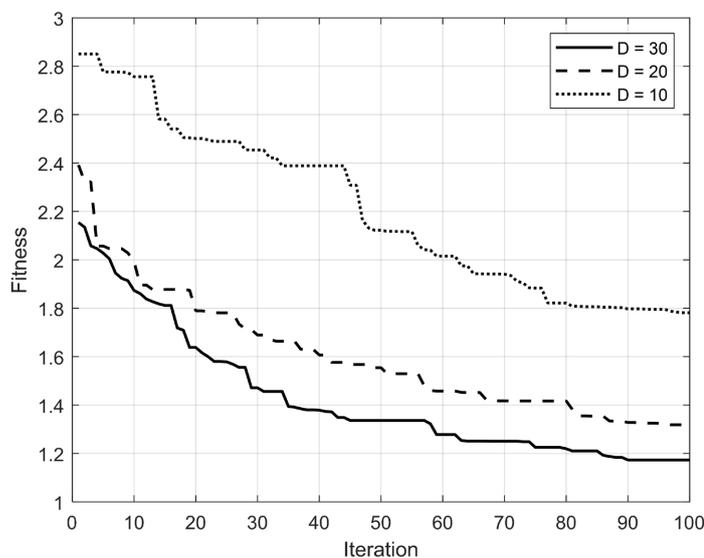


Figure 4. Convergence curve variations with different D values

图 4. 不同 D 值下的收敛曲线变化图

4.4. 性能指标

(1) 航迹成本

$$C_{\text{total cost}} = \left[\exp\left(-\frac{\sum_{i=1}^n \|d_i\|}{\delta}\right) \right] \cdot \gamma + \frac{\int d_j}{\|ST\|} \cdot (1-\gamma) \quad (7)$$

其中, 第一个部分 $\left[\exp\left(-\frac{\sum_{i=1}^n \|d_i\|}{\delta}\right) \right]$ 代表路径的威胁函数, 第二部分 $\frac{\int d_j}{\|ST\|}$ 代表路径函数。是基于概率密度模型计算的航迹成本, 表示无人机在飞行路径上遭受威胁的风险。它考虑了无人机与各个威胁中心的距离, 以及这些威胁的潜在影响。其中 n 是该区域内威胁源的总数。 d_i 是路径上的点到第 i 个威胁中心的距离。 δ 是控制概率密度函数形状的参数。 $\frac{\int d_j}{\|ST\|}$ 是经过标准化后的路径函数, 表示无人机的飞行航机路径得分。 d_j 表示第 j 条路径段的长度, $\|ST\|$ 代表起始点到终点连线的距离。 γ 代表重要程度, 本文均取 $\gamma = 0.5$, 代表路径长度和威胁风险在总成本中占有相同的比重。

(2) 算法稳定性

$$\text{Error}(\%) = \frac{\text{Average} - \text{BKS}}{\text{BKS}} \times 100\% \quad (8)$$

BKS 代表已知问题的最优解。 Best 代表算法运行 10 次所得到的最好解。 Average 代表 10 次运行结果的平均值。 Error 表示平均值 Average 与最优解 BKS 之间的相对误差, 这一指标用于评估算法的寻优性能 [19]。

4.5. 无人机航迹规划案例分析

为深入研究 AIGA 算法在多样化环境下的实际应用效果, 本研究设计了 9 个模拟无人机航迹规划案例, 这些案例基于三类不同类型的地图合集: 横向、纵向和斜向。这三种类型的地图分别代表了不同的飞行环境, 从而能够全面评估算法的适应性和鲁棒性。横向地图强调无人机在东西方向的移动, 纵向地图侧重南北方向的飞行, 而斜向地图则综合了多方向的路径规划, 以模拟更为复杂的实际飞行条件。

在每一类地图类型中, 我们进一步细分了三种不同雷达数目的地图场景: 少数目(10 个威胁源以下)、中等数量(10~13 个威胁源)和多数目(13 个威胁源以上)。雷达数目的不同代表了无人机在执行任务时可能遇到的不同程度的威胁密度。少数目雷达的场景可能对应低威胁环境, 而多数目雷达的场景则代表高风险区域, 这对无人机的安全性和路径合理性提出了更高要求。

通过 9 个不同的模拟案例(如图 5~13), 深入模拟了 AIGA (基于人工免疫的遗传算法)在横向、纵向和斜向环境上的无人机航迹规划能力。这些地图分别对应不同数量的威胁源, 从而模拟了从低到高的环境威胁程度。同时也将与粒子群优化算法(PSO)、人工蜂群算法(ABC)、禁忌搜索算法(TS)和遗传算法(GA)四种优化算法进行对比分析, 以全面评估 AIGA 算法在不同战术地图和威胁条件下的性能表现。

为了系统地评估无人机航迹规划算法在不同威胁环境下的性能, 我们设计了三个横向地图: MAP 1、MAP 2 和 MAP 3, 它们分别对应不同数量的威胁源。MAP 1 地图包含 10 个威胁源, 模拟了较为宽松的战术环境; MAP 2 地图包含 13 个威胁源, 代表中等威胁密度; 而 MAP 3 地图包含 16 个威胁源, 构建了一个高威胁密度的复杂环境。红色实线代表 AIGA 算法得出的优秀路径。

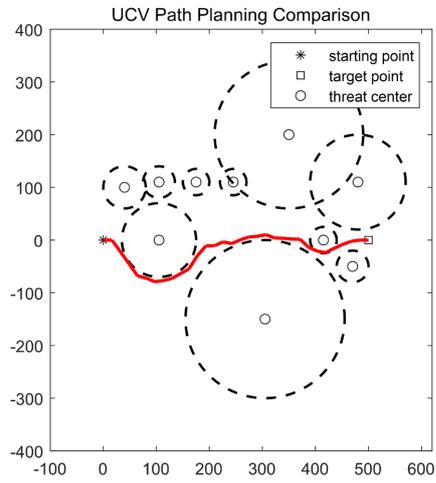


Figure 5. Map 1
图 5. Map 1 地图

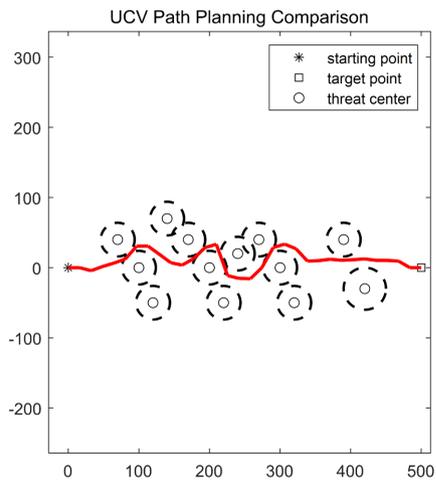


Figure 6. Map 2
图 6. Map 2 地图

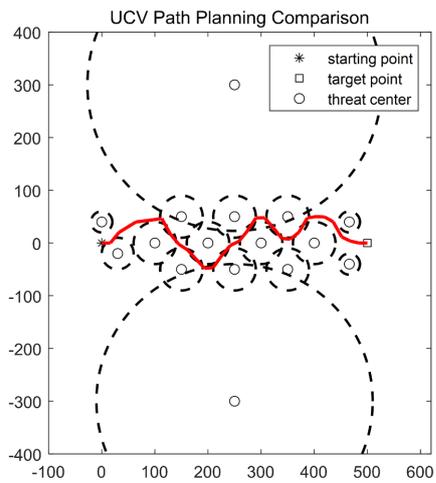


Figure 7. Map 3
图 7. Map 3 地图

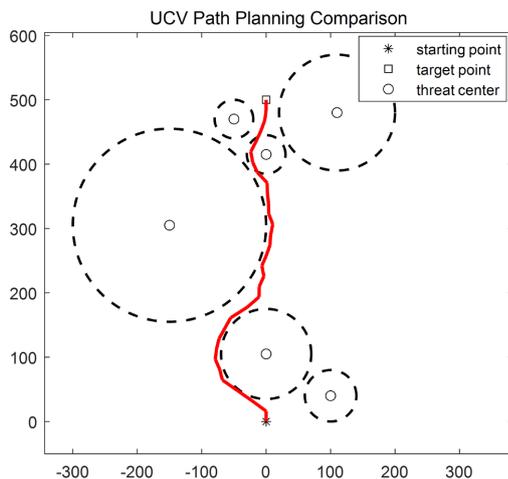


Figure 8. Map 4
图 8. Map 4 地图

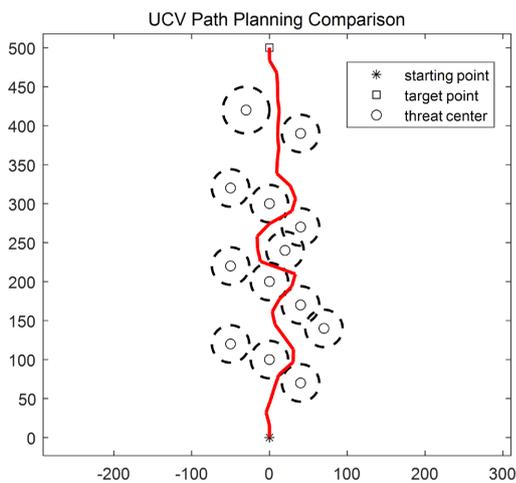


Figure 9. Map 5
图 9. Map 5 地图

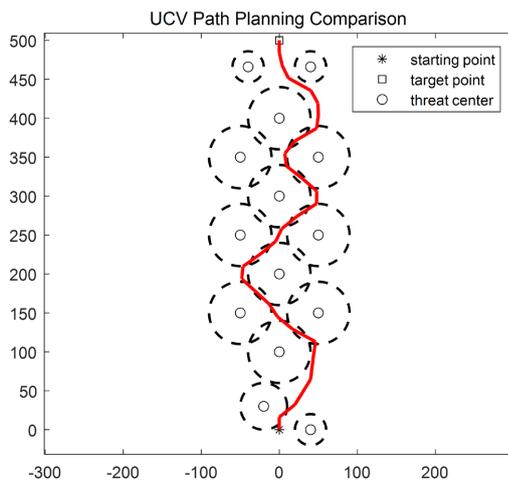


Figure 10. Map 6
图 10. Map 6 地图

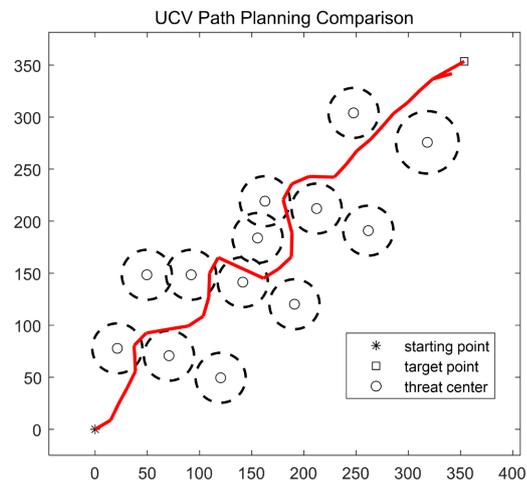


Figure 11. Map 7

图 11. Map 7 地图

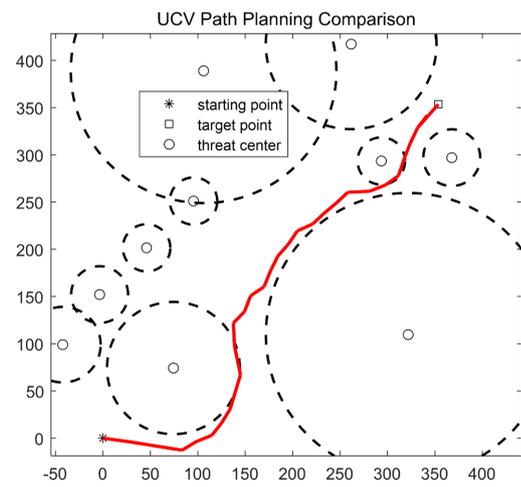


Figure 12. Map 8

图 12. Map 8 地图

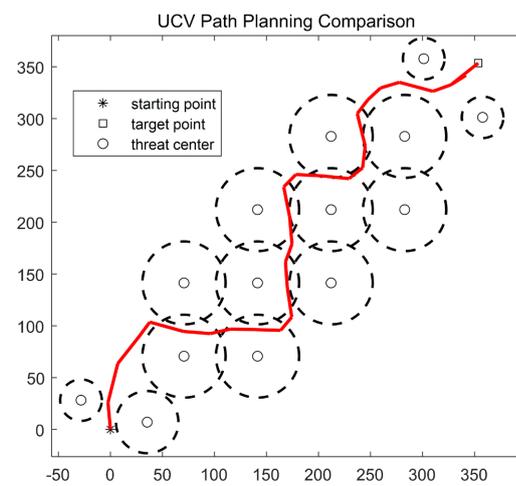


Figure 13. Map 9

图 13. Map 9 地图

三个纵向地图: MAP 4、MAP 5 和 MAP 6, 它们分别对应不同数量的威胁源。MAP 4 地图包含 6 个威胁源, 模拟了较为宽松的战术环境; MAP 5 地图包含 13 个威胁源, 代表中等威胁密度; 而 MAP 6 地图包含 14 个威胁源, 构建了一个高威胁密度的复杂环境。红色实线代表 AIGA 算法得出的优秀路径。

三个斜向地图: MAP 7、MAP 8 和 MAP 9, 它们分别对应不同数量的威胁源。MAP 4 地图包含 6 个威胁源, 模拟了较为宽松的战术环境; MAP 5 地图包含 13 个威胁源, 代表中等威胁密度; 而 MAP 6 地图包含 14 个威胁源, 构建了一个高威胁密度的复杂环境。红色实线代表 AIGA 算法得出的优秀路径。

Table 3. Comparison of error, best, and average values for five algorithms on nine maps

表 3. 五种算法在九个地图上的误差、最优值和平均值比较表

测试问题		ABC	PSO	TS	GA	AIGA
MAP 1		2.14	2.52	5.56	3.83	1.78
MAP 2		3.83	4.38	8.42	5.75	3.11
MAP 3		6.35	6.58	11.32	7.98	5.64
MAP 4		2.31	2.82	5.95	3.91	1.83
MAP 5	Avg	3.85	4.98	8.62	5.79	3.25
MAP 6		6.83	7.04	11.55	8.13	5.88
MAP 7		2.44	2.84	6.31	4.43	1.93
MAP 8		3.92	4.75	10.75	5.85	3.42
MAP 9		6.87	7.21	13.88	9.18	5.85
MAP 1		31.28	54.60	241.10	134.96	9.20
MAP 2		28.52	46.97	182.55	92.95	4.36
MAP 3		17.16	21.40	108.85	47.23	4.06
MAP 4		39.15	69.87	258.43	135.54	10.24
MAP 5	Error	24.19	60.64	178.06	56.77	4.83
MAP 6		20.88	24.60	104.42	43.89	4.07
MAP 7		34.80	56.90	192.60	144.75	6.62
MAP 8		18.07	43.07	223.79	76.20	3.01
MAP 9		22.02	28.06	146.53	63.05	3.90
MAP 1		1.94	2.04	5.26	3.53	1.63
MAP 2		3.37	3.77	8.22	5.12	2.98
MAP 3		5.88	6.32	10.02	7.63	5.42
MAP 4		2.21	2.71	5.58	3.59	1.66
MAP 5	Best	3.53	4.59	8.31	5.44	3.10
MAP 6		6.71	6.33	10.15	7.89	5.65
MAP 7		2.18	2.52	5.69	4.12	1.81
MAP 8		3.53	4.43	10.08	5.64	3.32
MAP 9		6.62	7.08	11.92	8.83	5.63

在实验中, 我们采用了九个不同的模拟案例(MAP 1 至 MAP 9), 每个案例都设计有独特的飞行环境和威胁分布。通过公式(1), 我们计算了五种算法(包括 AIGA 和其他四种启发式算法)在这些案例上的 Error 值。Error 值是一个关键的性能指标, 它衡量了算法找到的解与已知最优解(Best)之间的差距。此外, 我们还记录了每种算法运行十次后的平均值(AVG), 这反映了算法在多次运行中的一致性和稳定性。

实验结果如表 3 所示, AIGA 算法的 Error 值明显低于其他启发式算法, 这一结果表明 AIGA 在不同飞行环境下生成优秀航迹的能力更为稳定。低 Error 值意味着 AIGA 算法能够更频繁地接近最优解, 这是算法高效性和可靠性的重要体现。AVG 值的记录也证实了 AIGA 算法的稳定性。在多次运行中, AIGA 算法的平均性能表现优于其他算法, 这表明它能够在不同的情况下提供一致的解决方案质量。这种一致性对于实际应用中的无人机航迹规划至关重要, 因为它确保了算法在多变的环境中仍然能够提供可靠的路径。Best 值代表了算法在单次运行中找到的最优解。AIGA 算法在 Best 值上的表现同样出色, 这表明它不仅能够稳定地提供高质量的解, 而且还具备在特定情况下达到最优性能的潜力。

AIGA 算法之所以能够在这些性能指标上表现优异, 主要归功于其独特的动态疫苗库机制。AIGA 算法能够从动态变化的疫苗库中利用优良疫苗, 该策略允许算法根据环境的变化动态调整搜索策略, 从而在路径规划中实现更精确的风险评估和更有效的解探索。动态疫苗库的建立不仅提高了算法的搜索效率, 还增强了算法对环境变化的适应能力, 从而在面对不同飞行环境时, AIGA 算法能够灵活调整, 保持鲁棒性。

5. 结论

本研究针对无人机航迹规划问题, 提出了一种基于人工免疫的遗传算法(AIGA)。通过构建动态疫苗库并引入优良疫苗的概念, 为解决无人机航机规划提出了新思路。

实验部分通过与多种启发式算法的比较, 如粒子群优化(PSO)算法和人工蜂群(ABC)算法等多种启发式算法, 证明了 AIGA 在路径优化测试问题上的有效性和优越性。AIGA 算法不仅在收敛速度上表现更佳, 而且在生成安全、经济飞行路径方面也显示出了卓越的性能。此外, 通过在不同地图环境下的案例分析, 进一步证实了 AIGA 算法的鲁棒性和适应性。

尽管 AIGA 在本案例中表现出色, 但我们认识到, 任何算法的性能都受到其设计假设和应用场景的限制。未来的工作将探索 AIGA 在更大规模和更复杂环境下的应用, 以及如何进一步优化算法参数以适应不同的实际需求。此外, 我们也将考虑将 AIGA 与其他优化技术结合, 以寻求在特定问题上的性能突破。

随着无人机技术的不断发展和应用领域的不断扩展, AIGA 算法有望在未来的无人机路径规划任务中发挥重要作用。未来的工作将进一步探索 AIGA 在更大规模和更复杂环境下的应用, 并考虑与其他智能优化算法的集成, 以寻求在无人机航迹规划领域的新突破。

基金项目

广东省自然科学基金项目(2021A1515011839)。

参考文献

- [1] 唐强, 张翔伦, 左玲. 无人机航迹规划算法的初步研究[J]. 航空计算技术, 2003, 33(1): 125-128, 132.
- [2] 边霞, 米良. 遗传算法理论及其应用研究进展[J]. 计算机应用研究, 2010, 27(7): 2425-2429, 2434.
- [3] 杨启文, 蔡亮, 薛云灿. 差分进化算法综述[J]. 模式识别与人工智能, 2008, 21(4): 506-513.
- [4] 崔长彩, 李兵, 张认成. 粒子群优化算法[J]. 华侨大学学报(自然科学版), 2006, 27(4): 343-347.

-
- [5] 靳文舟, 邓钦原, 郝小妮, 等. 改进人工蜂群算法的农村 DRT 路径优化研究[J]. 郑州大学学报(工学版), 2021, 42(4): 84-90.
- [6] Zhang, H., Gan, X., Li, S. and Chen, Z. (2022) UAV Safe Route Planning Based on PSO-BAS Algorithm. *Journal of Systems Engineering and Electronics*, **33**, 1151-1160. <https://doi.org/10.23919/jsee.2022.000111>
- [7] Bi, R., Gan, S., Yuan, X., Li, K., Li, R., Luo, W., et al. (2024) Detection and Analysis of Landslide Geomorphology Based on UAV Vertical Photogrammetry. *Journal of Mountain Science*, **21**, 1190-1214. <https://doi.org/10.1007/s11629-022-7766-y>
- [8] 于军琪, 陈易圣, 冯春勇, 等. 智能建造机器人局部路径规划研究综述[J]. 计算机工程与应用, 2024, 60(10): 16-29.
- [9] 王福仪, 孟秀云, 张海阔. 基于 ε -level 蝙蝠算法的无人机三维航迹规划[J]. 北京航空航天大学学报, 2024, 50(5): 1593-1603.
- [10] 杨柳庆, 王鹏飞, 张勇. 基于羊群算法的多机协同航路规划[J]. 南京航空航天大学学报(英文版), 2020, 37(5): 816-830.
- [11] Gong, M.-G., et al. (2012) Community Detection in Dynamic Social Networks Based on Multiobjective Immune Algorithm. *Journal of Computer Science & Technology*, **27**, 455-467.
- [12] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究[J]. 软件学报, 2009, 20(2): 271-289.
- [13] 郭鑫, 李立君. 基于人工免疫-改进粒子群优化算法的机械臂轨迹规划研究[J]. 机械传动, 2024, 48(5): 33-40.
- [14] Kaymaz, M., Ayzit, R., Akgün, O., Atik, K.C., Erdem, M., Yalcin, B., et al. (2024) Trading-Off Safety with Agility Using Deep Pose Error Estimation and Reinforcement Learning for Perception-Driven UAV Motion Planning. *Journal of Intelligent & Robotic Systems*, **110**, Article No. 55. <https://doi.org/10.1007/s10846-024-02085-4>
- [15] 曹璐, 贾银平, 张安. 基于改进人工蜂群算法的多无人作战飞机协同航迹规划[J]. 计算机应用, 2013, 33(12): 3596-3599, 3603.
- [16] 马永杰, 云文霞. 遗传算法研究进展[J]. 计算机应用研究, 2012, 29(4): 1201-1206, 1210.
- [17] 吉根林. 遗传算法研究综述[J]. 计算机应用与软件, 2004, 21(2): 69-73.
- [18] 徐嘉琦, 田野. 基于改进遗传算法的柔性流水车间调度研究[J]. 制造技术与机床, 2024(4): 181-187.
- [19] 王永, 吕致为. 基于基因库求解旅行商问题的遗传算法[J]. 计算机应用研究, 2023, 40(11): 3262-3268.