

基于改进黏菌算法的无人船全局路径规划

刘金科 梁作鹏 蒲泽森 杨 祎 周世波

(集美大学航海学院 厦门 361021)

摘要:高质量的全局路径规划是无人船艇(unmanned surface vehicle, USV)自主航行的关键技术之一。针对 USV 复杂障碍环境下全局路径规划问题,提出一种基于多策略优化黏菌算法(multi-strategy enhanced slime mould algorithm, ME-SMA)的全局路径规划方法。ME-SMA 针对黏菌算法(slime mould algorithm, SMA)存在初始种群分布不均、收敛速度慢及易陷入局部最优等问题,通过改进的 Logistic 混沌映射优化种群初始化,增强全局搜索能力;结合遗传算法(genetic algorithm, GA)的交叉、变异及选择策略,提升局部开发效率;引入黄金正弦策略动态调整搜索方向,避免早熟收敛。为验证 ME-SMA 的有效性,在 9 类基准测试函数上进行了测试。实验结果表明,相较于原始 SMA 及其他对比算法,ME-SMA 展现出较好的收敛精度与稳定性。在相同复杂障碍环境下进行的仿真实验表明,ME-SMA 在收敛速度、任务完成时间及航行距离等方面均有显著提升,与其余实验算法进行对比,路径长度均值平均减少 1.8%,稳定性平均提升 28.22%,凸显了其在 USV 全局路径规划应用中的高效性与工程实用价值。

关键词:黏菌算法;Logistic 混沌映射;遗传策略;黄金正弦算法;路径规划

中图分类号: TP391;TN98

文献标识码: A

国家标准学科分类代码: 580.40

Enhanced Slime Mould Algorithm-based global path planning for unmanned surface vehicles

Liu Jinke Liang Zuopeng Pu Zesen Yang Yi Zhou Shibo

(Navigation College, Jimei University, Xiamen 361021, China)

Abstract: High-quality global path planning is one of the key technologies enabling autonomous navigation of unmanned surface vehicles (USVs). To address the global path planning problem for USVs in complex obstacle environments, this paper proposes a global path planning method based on the multi-strategy enhanced slime mould algorithm (ME-SMA). To overcome SMA's limitations such as uneven initial population distribution, slow convergence speed, and proneness to local optima, ME-SMA employs several enhancements: it optimizes population initialization using improved Logistic chaotic mapping to enhance global exploration; incorporates crossover, mutation, and selection strategies from genetic algorithms to improve local exploitation efficiency; and introduces the golden sine strategy to dynamically adjust the search direction, thereby avoiding premature convergence. To validate the effectiveness of ME-SMA, we tested it on nine types of benchmark functions. The results show that ME-SMA achieves superior convergence accuracy and stability compared to the original SMA and other comparative algorithms. Simulation experiments in identical complex obstacle environments further demonstrate that ME-SMA significantly improves convergence speed, task completion time, and navigation distance. Compared to the other experimental algorithms, ME-SMA achieves an average reduction of 1.8% in path length and an average improvement of 28.22% in stability, highlighting its high efficiency and practical engineering value for USV global path planning applications.

Keywords: slime mould algorithm; logistic chaotic mapping; genetic strategy; golden sine algorithm; path planning

0 引言

近年来,海洋经济的快速发展和无人系统的进步引

起了研究者对无人船艇(unmanned surface vehicle, USV)的广泛关注。USV 是一种新型的智能无人水面平台,能够在复杂的水域环境中完成各种任务^[1],在资源勘探^[2]、环境监测^[3]、水面搜救^[4]和军事协同^[5]等领域的应用日

益广泛。然而,由于 USV 所行驶环境的复杂性,其航行路径容易受到障碍物的影响,因此,采取合适的全局路径规划策略是实现 USV 无人化系统的重要前提条件,这可以减少航行时间与能耗,提高作业效率和降低航运成本^[6],对于 USV 安全和高效完成各项任务完成具有重要意义。

路径规划算法大致可分为 4 类,图形搜索算法、虚拟势场法、随机采样算法和群智能算法^[7]。图形搜索算法, A* 算法^[8]、Dijkstra 算法^[9]、Floyd 算法^[10]等,这类算法由于优秀的数学基础与理论,因此在静态环境中表现良好,但在动态或复杂场景中因计算复杂度高、实时适应性差而表现欠佳^[11]。虚拟势场法,人工势场法 (artificial potential field, APF)^[12]、快速行进法 (fast marching method, FMM)^[13],这类算法可以实时调整路径以避开障碍物,响应速度较快,在动态环境中表现优异,但在复杂场景中容易陷入局部最优^[14]。随机采样算法,如快速随机搜索树算法 (rapidly-exploring random tree, RRT)^[15]、概率路标算法 (probabilistic roadmap method, PRM)^[16],这类算法适用于多维空间的全局路径规划,算法搜索路径速度较快,但由于其使用全局均匀随机采样,在复杂场景中存在易陷入局部最小值问题^[17]。群智能算法,粒子群算法 (particle swarm optimization, PSO)^[18]、蚁群算法 (ant colony algorithm, ACA)^[19]、遗传算法 (genetic algorithm, GA)^[20]等,这类算法对环境适应力强,擅长全局优化,但计算效率相对较低^[21]。

上述各类算法在路径规划中均有着广泛的应用,其中群智能算法在复杂环境下的路径搜索问题中展现出显著优势使其成为全局路径规划的主流方法。群智能算法模拟自然界中生物群体的集体行为,通过学习群体内彼此的经验来寻找最优的解决方案。常见的群智能算法有海鸥算法 (seagull optimization algorithm, SOA)^[22]、鲸鱼算法 (whale optimization algorithm, WOA)^[23]、人工蜂群算法 (artificial bee colony, ABC)^[24]、麻雀算法等 (sparrow search algorithm, SSA)^[25]。研究者还将灰狼算法 (grey wolf optimizer, GWO)^[26]、烟花算法 (fireworks algorithm, FWA)^[27]等,这些算法应用于路径规划,取得了良好的效果。

黏菌算法 (slime mould algorithm, SMA)^[28]通过模拟黏菌觅食行为实现优化,在全局路径规划中展现出巨大的潜力。Zheng 等^[29]将 SMA 与自适应技术结合来增强全局搜索能力,并集成了人工势场以提高动态避障能力。刘美娇^[30]将黏菌算法与蚁群算法结合,用于机器人足端路径规划。但其在初始种群分布不均、收敛速度慢及易陷入局部最优等方面的不足限制了进一步应用^[31]。针对上述问题,研究者们提出了多种改进策略,Zhang 等^[32]设计了一种新的自适应柯西突变算子用于增强种群多样

性;Houssein 等^[33]将自适应引导差分进化算法 (AGDE) 与 SMA 结合,利用 AGDE 的变异策略增强局部搜索能力;Hassan 等^[34]引入正弦-余弦算法 (SCA) 的扰动机制,动态调整解的更新方向,改善全局收敛性;Samantaray 等^[35]与 Chakraborty 等^[36]分别使用与 PSO 进行融合的方法和二次项逼近的策略增强 SMA 的局部搜索能力;Chauhan 等^[37]将算术优化算法 (arithmetic optimization algorithm, AOA) 和透镜成像对立学习策略与 SMA 进行融合,提高了 SMA 的局部收敛性;Xiong 等^[38]将差分进化策略和莱维飞行策略与 SMA 结合提高了算法的求解精度。

上述研究虽取得显著进展,但在路径规划任务中仍面临些许挑战,如路径连续性难以保证、避障能力不足、计算效率低下等。为解决所述不足,提出一种多策略优化的黏菌算法 (ME-SMA),通过有机融合多种互补性强的优化策略,系统性解决 SMA 的部分不足,并针对性地提升其在 USV 全局路径规划任务中的综合性能 (如路径质量、平滑性、安全性和计算效率等)。

本文使用改进的 Logistic 混沌映射初始化种群,增加初始种群分布的离散性和均匀性,克服随机初始化分布不均的问题,确保种群多样性,相较于标准 SMA 及单一混沌初始化策略效果更优,提高算法后续的寻优效率;结合交叉、变异等遗传操作,增强算法的全局搜索能力,并利用黄金分割系数和正弦函数的非线性特性,分割搜索空间的同时避免算法出现早熟现象,引导种群收敛至最优区域,区别于仅使用固定参数或简单线性调整的策略,该策略有效防止算法后期停滞;使用三次样条对规划路径进行平滑处理,减少不必要的转向点,缩短路径长度。

在相同复杂障碍环境下进行的仿真实验表明,ME-SMA 在 USV 全局路径规划应用中效率较高,具有良好的工程实用价值。

1 多策略优化的黏菌算法

1.1 黏菌算法

黏菌算法通过模拟自然界中黏菌生物的捕食行为来实现智能寻优功能。假设黏菌种群数量为 N ,每个个体均包含 D 个维度,则可以将整个种群表示为:

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^D \\ x_2^1 & x_2^2 & \cdots & x_2^D \\ \vdots & \vdots & & \vdots \\ x_N^1 & x_N^2 & \cdots & x_N^D \end{bmatrix} = \begin{bmatrix} \vec{X}_1 \\ \vec{X}_2 \\ \vdots \\ \vec{X}_N \end{bmatrix} \quad (1)$$

适应度和黏菌在接近食物的过程中的位置更新方式可以分别表示为:

$$f(\mathbf{X}) = [f(\vec{X}_1), f(\vec{X}_2), \dots, f(\vec{X}_N)] \quad (2)$$

$$\vec{X}(t+1) = \begin{cases} rand \times (ub - lb) + lb, & r < z \\ \vec{X}_b(t) + \vec{vb} \times (\vec{W} \times \vec{X}_A(t) - \vec{X}_B(t)), & r < p \\ \vec{vc} \times \vec{X}(t), & r \geq p \end{cases} \quad (3)$$

式中: $\vec{X}(t)$ 表示第 t 次迭代时黏菌的位置向量; $\vec{X}_b(t)$ 表示第 t 次迭代时食物浓度最高的位置向量; \vec{vb} 和 \vec{vc} 为震荡参数; \vec{W} 为权重系数,三者影响黏菌的搜索过程; $rand$ 和 r 表示范围 $[0,1]$ 的随机数; ub 和 lb 表示搜索空间上界和下界; z 是平衡搜索与开发阶段的参数。

1.2 SMA 流程

SMA 通过模拟黏菌行为实现优化。首先设定种群规模、最大迭代次数、变量范围等参数,并随机初始化黏菌种群的位置;随后进入迭代过程,在每次迭代中计算所有个体的适应度值,对个体按适应度排序并更新全局最优解及其对应的最优适应度;然后动态调整惯性权重参数 \vec{W} ,再依次更新每个搜索位置的移动参数;最后更新黏菌个体的位置。迭代完成后,输出全局最优适应度值及对应的最优解。SMA 伪代码如算法 1 所示。

算法 1 SMA 伪代码

```

初始化参数: popsize, IterMax, lb, ub;
初始化黏菌种群位置  $X_i (i = 1, 2, \dots, n)$ ;
While  $t \leq Iter_{Max}$ 
    计算所有黏菌个体的适应度;
    对黏菌个体进行排序并更新 bestFitness,  $X_b$ 
    更新权重系数  $W$ ;
    For each 搜索位置
        更新参数  $p, \vec{vb}, \vec{vc}$ ;
        按照式(3)更新位置;
    End For
     $t = t + 1$ ;
End While
Return bestFitness,  $X_b$ 

```

2 多策略改进的黏菌优化算法

2.1 Logistic 混沌映射

种群初始化的情况将会直接影响群智能优化算法的效率。SMA 中的初始化种群是随机生成的,随机数法的缺点是种群无法均匀的分布在搜索空间内,影响后续算法的求解效率。混沌运动具有遍历性和不重复性等特点,适合用来生成种群的初始位置。因此,本文采用 Logistic 混沌映射产生混沌序列,丰富种群多样性,使种

群均匀分布在搜索空间内,避免算法陷入局部最小值。其定义如下:

$$Y_{n+1} = r \times Y_n \times (1 - Y_n) \quad (4)$$

式中: r 为控制参数,取值为 $(0,4]$ 。

Logistic 混沌映射具有较好的混沌特性,参数的选取对其混沌性有着密切的影响,如图 1 所示。图 1(a)和(b)分别是 Logistic 映射的分叉图和直方图,从分叉图中不难看出,参数 r 在 $(0,3)$ 区间内, Y 值最终会收敛到一个稳定平衡点, r 取值为 3 时,稳定点失衡, $r \approx 3.57$ 时,系统进入混沌状态。 r 的取值越接近 4,其混沌特性越优秀。同时 Y_n 的值越均匀的分布在 $[0,1]$ 区间内。当 $r = 4$ 时,整个系统处于完全混沌状态。Logistic 映射的混沌区间相对较窄,并且由直方图可以看出虽然生成的混沌序列取值均匀,但概率并不均等,数据出现向区间两端聚集的现象。为了克服上述问题,对 Logistic 映射公式进行改进,改进后如式(5)所示。

$$Y_{n+1} = r \times \left(1 - \frac{\pi}{\sin Y_n^2}\right) \bmod 1 \quad (5)$$

其中, \bmod 为取模符号。改进后的分叉图和直方图如图 1(c)、(d)所示。从改进后的分叉图中可以看出,改进后的 Logistic 映射的混沌区间相比之下有了极大的增加,并且由直方图可以看出混沌序列的取值分布更加均匀,更便于后续生成随机的初始化种群。

因此,将式(5)引入 SMA 初始化过程中,如式(6)所示。

$$x_i^d = Y_i^d \times ub_d + (1 - Y_i^d) \times lb_d \quad (6)$$

选取式(5)产生的初始变量值,然后利用式(6)映射到黏菌个体上,产生多样性较好的初始种群。令搜索上下界分别为 1 和 0,维度为 1,个体数量设置为 600,随机策略与该策略在搜索空间生成的初始化种群如图 2 所示。

从图 2 可以看出,改进 Logistic 策略生成的初始化种群分布较随机策略的种群分布更加均匀,因此在标准黏菌算法中融入改进 Logistic 混沌映射,确保种群多样性,提高算法的寻优效率。

2.2 遗传学习策略

SMA 中,新个体主要通过 X_A 和 X_B 在全局范围内生成,优良个体的引导作用没有很好的发挥出来,进化存在盲目性,影响算法的收敛速度。与之相比,遗传算法中的选择、交叉、变异操作使得 GA 具有更强的全局搜索能力。因此,引入遗传学习策略,提高 SMA 的性能。

1) 交叉操作。个体 i 的优秀后代 $I_i = [I_{i1}, I_{i2}, I_{i3}, \dots, I_{id}]$ 通过式(7)得到。

$$I_{id}^{new} = \begin{cases} r \times I_{id}^b + (1 - r) \times I_{id}^d, & f(I_i^b) < f(I_k^b) \\ I_{id}^b, & \text{其他} \end{cases} \quad (7)$$

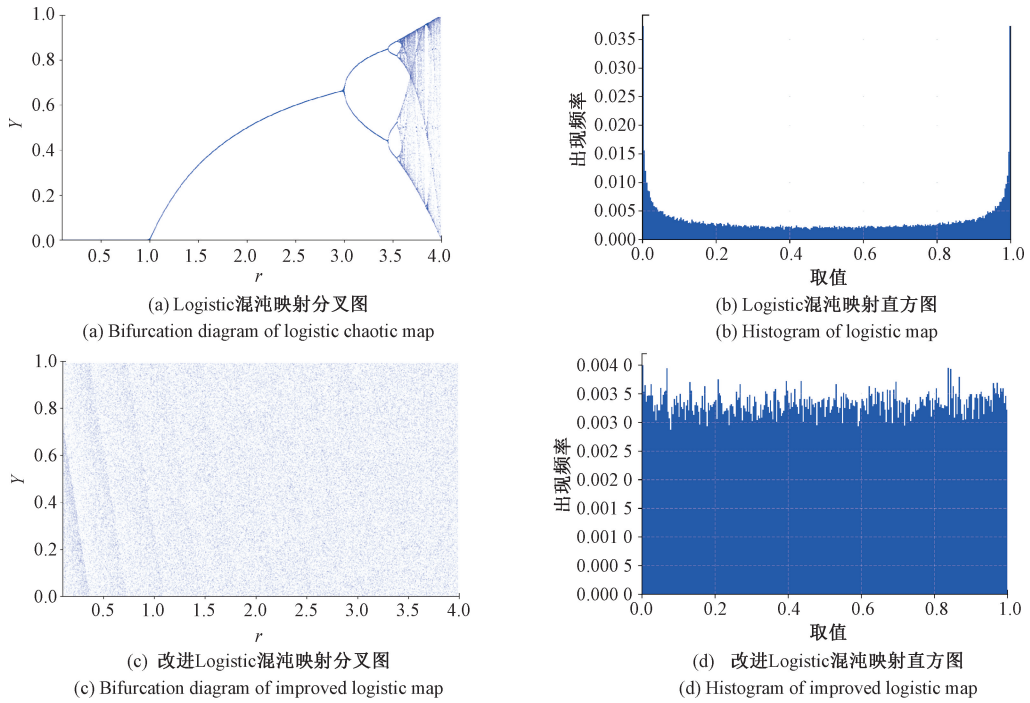


图 1 混沌映射分岔图和直方图

Fig. 1 Chaos map bifurcation diagram and histogram

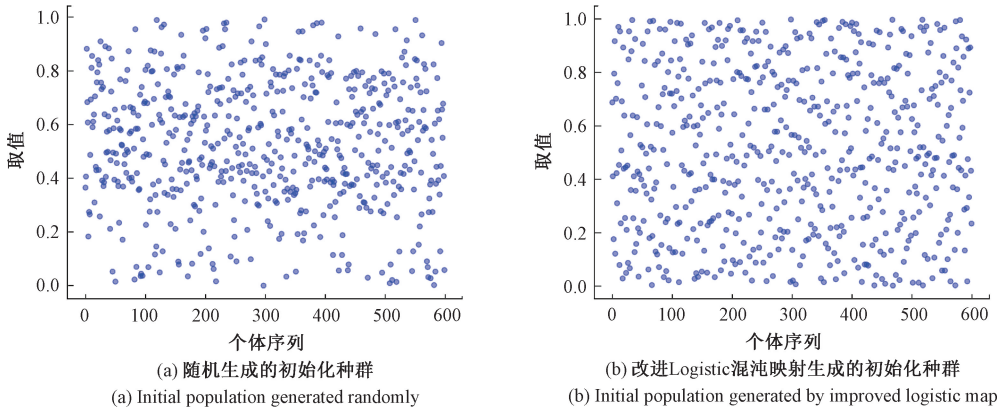


图 2 初始化方法效果对比

Fig. 2 Comparison of initialization method effects

式中: r 是分布在 $[0, 1]$ 之间的随机数; k 是集合 $\{1, 2, 3, \dots, N\}$ 中的随机数; I_{id}^b 是个体 i 的历史最优位置的 d 维的值; I_i^b 、 I_k^b 分别是个体 i 和个体 k 的历史最优位置; I_{bd} 是全局最优个体的 d 维的值。交叉操作通过计算 I_{id}^b 和 I_{bd} 的凸组合,使个体向最优个体靠近,整合局部与全局个体的位置信息,加快算法收敛。

2) 变异操作。后代第 d 维的变异具体操作如式(8)所示。

$$I_{id}^{new} = \begin{cases} r \times ub_d + (1 - r) \times lb_d, & r < p_m \\ I_{id}, & \text{其他} \end{cases} \quad (8)$$

式中: ub_d 和 lb_d 分别是搜索空间的上界与下界的 d 维约束; p_m 是变异概率。变异操作通过对个体 d 维的扰动,提高种群多样性,避免算法陷入局部最优解。

3) 选择操作。对个体精英后代的选择具体操作如式(9)所示。

$$\vec{I}_i^E = \begin{cases} \vec{I}_i^{new}, & f(\vec{I}_i^{new}) < f(\vec{I}_i^E) \\ \vec{I}_i^E, & \text{其他} \end{cases} \quad (9)$$

选择操作使得个体子代适应度优于父代。改进后的更新公式如下:

$$\overrightarrow{X}(t+1) = \begin{cases} rand \times (ub - lb) + lb, & rand < z \\ \overrightarrow{X_b}(t) + \overrightarrow{vb} \times (\overrightarrow{W} \times \overrightarrow{X_A}(t) - \overrightarrow{I^E}(t)), & r < p \\ \overrightarrow{vc} \times \overrightarrow{X}(t), & r \geq p \end{cases} \quad (10)$$

2.3 黄金正弦学习策略

引入遗传策略后,每个子代的适应度都优于父代,但会导致算法出现早熟现象。因此,引入黄金正弦算法(golden sine algorithm, GSA)^[39],利用正弦函数结合黄金正弦分割比例,来提升寻优性能的一种方法。在迭代过程中,融入黄金分割系数,使算法不断缩小搜索空间,在很大程度上提升了种群的搜索效率,使其具有鲁棒性高、收敛快、精度高等特点。通过随机方式生成数量为 N 的初始候选解以填充搜索空间,提升黏菌算法的搜索效率,黄金正弦算法更新策略如下:

$$\mathbf{V}_i^{t+1} = \mathbf{V}_i^t |\sin r_1| - r_2 \sin r_1 |x_1 \mathbf{D}_i^t - x_2 \mathbf{V}_i^t| \quad (11)$$

式中: \mathbf{V}_i^{t+1} 和 \mathbf{V}_i^t 分别是第 i 个个体第 $t+1$ 迭代和第 t 次迭代的位置; \mathbf{D}_i^t 是第 i 个个体第 t 次迭代的最优位置; r_1 为区间 $[0, 2\pi]$ 内的随机数; r_2 为区间 $[0, \pi]$ 内的随机数; x_1, x_2 为黄金分割系数。相关表达式如式(12)~(14)所示。

$$x_1 = -\pi + \tau \times 2\pi \quad (12)$$

$$x_2 = -\pi + (1 - \tau) \times 2\pi \quad (13)$$

$$\tau = \frac{\sqrt{5} - 1}{2} \quad (14)$$

通过每次迭代对搜索空间的缩减,引导黏菌算法不断向最优解趋近。

2.4 ME-SMA 算法

改进后算法首先通过混沌映射初始化黏菌种群的位置,然后在每次迭代中计算个体适应度并更新全局最优解;基于动态调整的权重参数优化搜索方向,结合精英种群策略保留优质解,并通过两阶段位置更新公式分别实现全局探索与局部开发。算法在达到最大迭代次数后输出最优适应度值及对应解。ME-SMA 伪代码如算法2所示。

3 ME-SMA 性能测试分析

3.1 测试函数

为了验证 ME-SMA 寻优能力的强弱,选取了一组基准测试函数对算法性能优劣进行比较,函数由3种类型的问题组成:可扩展单峰函数($F_1 \sim F_3$)、可扩展多峰函数($F_4 \sim F_6$)、固定维的多峰函数($F_7 \sim F_9$)。测试函数的具体描述如表1所示。

算法2 ME-SMA 算法

初始化参数: $popsiz$, $Iter_{Max}$, p_m , lb , ub ;

融合改进的 Logistic 混沌映射方法初始化黏菌种群的位置 $X_i(i = 1, 2, \dots, n)$;

While $t \leq Iter_{Max}$

 计算所有黏菌个体的适应度;

 更新 $bestFitness$, X_b

 更新权重系数 W ;

 For each 搜索位置

 更新精英种群 \vec{I}_i^E ;

 更新 p, \vec{vb}, \vec{vc} ;

 按照公式(10)更新位置;

 End For

 按照公式(11)更新位置;

$t = t + 1$;

End While

Return $bestFitness$, X_b

3.2 参数分析

参数 z 是平衡搜索与开发阶段的参数。利用9个测试函数来评估参数 z 对算法的影响。参数 z 的范围为 $[0, 0.1]$, 设置11个值, 每个值的间隔是0.01。在其他条件不变的情况下, 在9个测试函数中测试了参数 z 的不同值, 结果如表2所示。表2中的值表示运行某一函数时, 不同 z 值的排名。

通过对表2的实验结果分析, 可以发现当参数 $z = 0.03$ 时, 该算法能够更有效地平衡搜索能力与优化效率之间的关系, 从而获得更优的性能表现。

为深入探究种群规模(population)和最大迭代次数(iteration)对算法性能的影响, 选取基准测试函数 F_1 作为评估对象, 对上述两个参数进行了测试。具体实验设计为: 种群规模分别设置为5、10、50、100、300和500; 最大迭代次数分别设置为50、100、200、500、1 000和2 000。为确保结果的统计可靠性, 每个参数组合进行30次独立重复实验, 并计算其寻优结果的平均值作为最终结果。

测试结果如图3所示, 从图3可以看出, 在迭代初期, 增大种群规模有助于显著提升算法的全局搜索效率。相应地, 增加迭代次数则对算法在优化后期的局部搜索精度具有明显的促进作用。

由于算法在迭代前期已能较快地收敛至近似最优解区域, 当种群规模与迭代次数持续增大并超过某一阈值后, 性能的进一步改善变得极其有限, 呈现出显著的边际效益递减现象。

3.3 实验验证

利用9种测试函数评估 ME-SMA 的性能, 实验算法选择 SMA、GSA、蝴蝶优化算法(butterfly optimization algorithm, BOA)^[40]、SOA 以及 WOA 进行对比评估。

表 1 测试函数相关参数

Table 1 Related parameters of test functions

函数类型	表达式	维度	全局最优值
单峰测试函数	$F_1(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i)^2] + (x_i - 1)^2$	30	0
	$F_2(x) = \sum_{i=1}^n (x_i + 0.5)^2$	30	0
	$F_3(x) = \sum_{i=1}^n ix_i^4 + random[0,1)$	30	0
多峰测试函数	$F_4(x) = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10)$	30	0
	$F_5(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	0
	$F_6(x) = \frac{1}{4000}\sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	0
固定维多峰测试函数	$F_7(x) = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6}\right]^{-1}$	2	1
	$F_8(x) = -\sum_{i=1}^4 c_i \exp\left[-\sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2\right]$	6	-3.32
	$F_9(x) = -\sum_{i=1}^{10} ((X - a_i)(X - a_i)^T + c_i)^{-1}$	4	-10.536 3

表 2 不同 z 值产生的结果排名

Table 2 Ranking of results generated by different Z-values

函数	z=0	z=0.01	z=0.02	z=0.03	z=0.04	z=0.05	z=0.06	z=0.07	z=0.08	z=0.09	z=0.1
F_1	6	5	4	8	9	2	10	11	7	3	1
F_2	10	11	3	9	7	8	6	4	5	2	1
F_3	10	11	3	9	7	8	6	4	5	2	1
F_4	3	8	4	1	6	5	2	7	11	10	9
F_5	7	1	9	6	8	3	2	4	5	10	11
F_6	1	1	1	1	1	1	1	1	1	1	1
F_7	1	1	1	1	1	1	1	1	1	1	1
F_8	1	1	1	1	1	1	1	1	1	1	1
F_9	2	5	8	1	3	4	6	9	10	11	7
平均值	3.78	3.78	3.67	3.56	5	4	4	5.11	5.22	5.44	4.11
排名	3	3	2	1	8	5	5	9	10	11	7

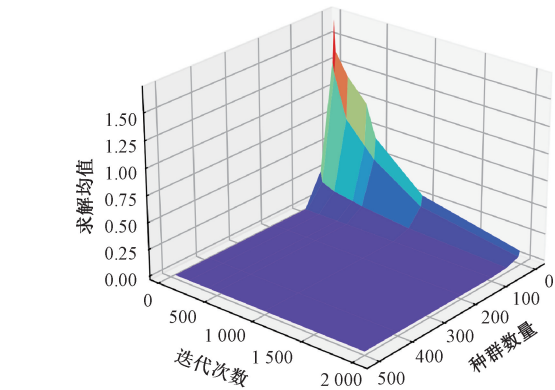


图 3 种群规模与迭代次数对结果的影响

Fig. 3 The influence of population size and iteration times on results

图 4~6 所示分别为 9 种测试函数的搜索空间拓扑结构,以及各算法在 30 次独立运行中适应度值(Fitness)随迭代次数 t 的演化曲线。从图 4~6 可以看出,ME-SMA 在绝大多数函数上表现出更快的收敛速度和更优的最终精度。

表 3 为 30 次重复实验的统计指标,包括最优适应度值、平均适应度值和适应度值的标准差。从寻优结果可以看出,ME-SMA 在除一个测试函数外(其寻优结果略逊于标准 SMA),在其余所有测试函数上的寻优结果均优于其他对比算法,同时,ME-SMA 在绝大多数函数上表现出更小的标准差,充分验证了改进策略能有效提升算法的鲁棒性。

图 7 所示为在 9 个测试函数上 6 种对比算法性能排

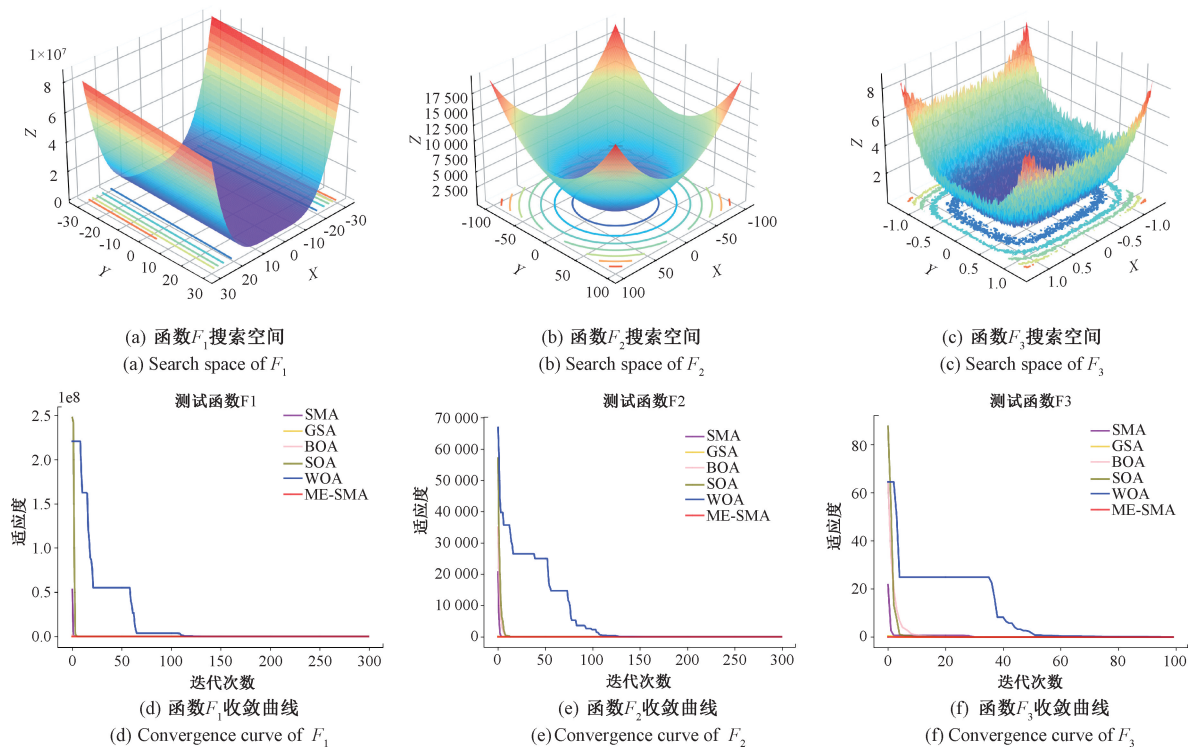


图4 单峰函数搜索空间与各算法收敛曲线

Fig. 4 Search space of unimodal functions and convergence curves of various algorithms

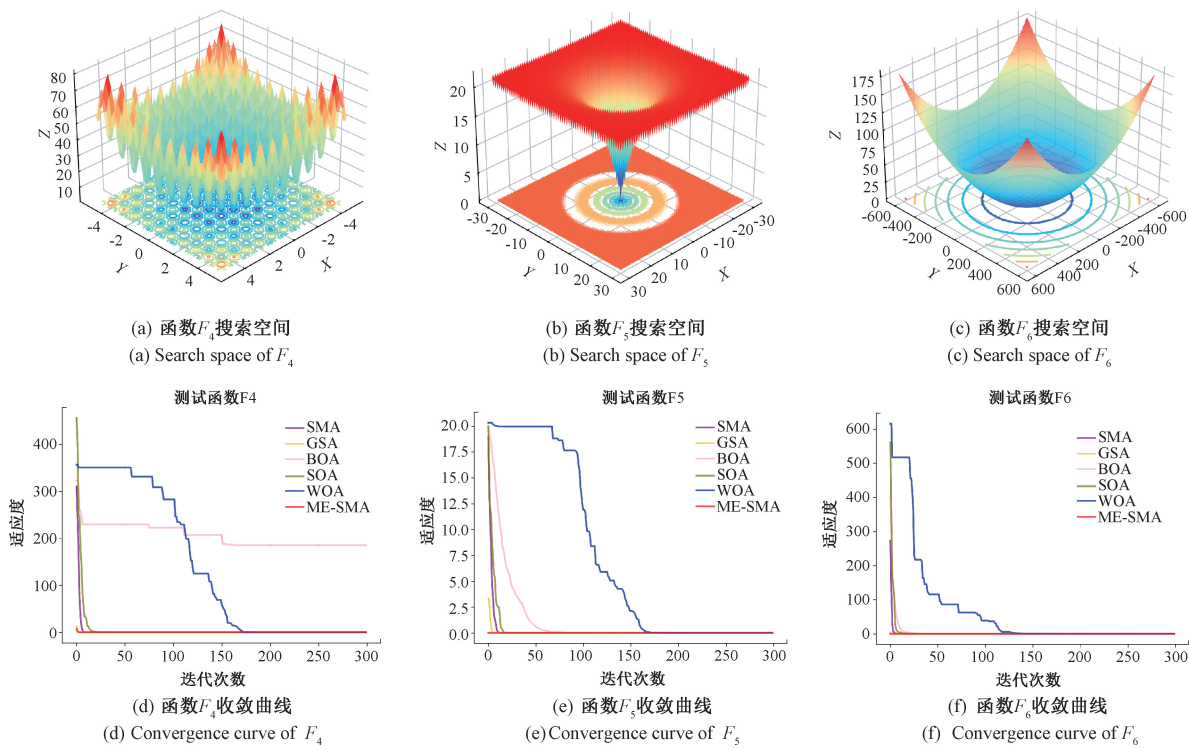


图5 多峰函数搜索空间与各算法收敛曲线

Fig. 5 Search space of multimodal functions and convergence curves of various algorithms

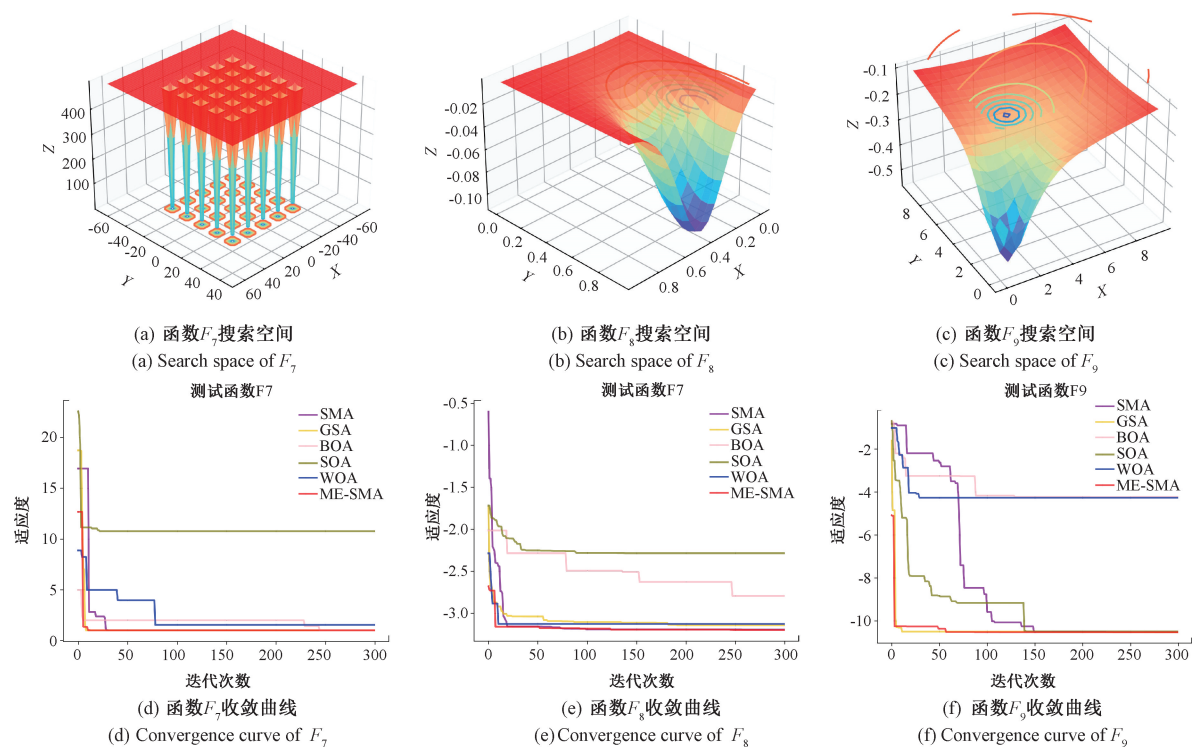


图 6 固定维多峰函数搜索空间与各算法收敛曲线

Fig. 6 Search space of fixed dimensional multimodal function and convergence curves

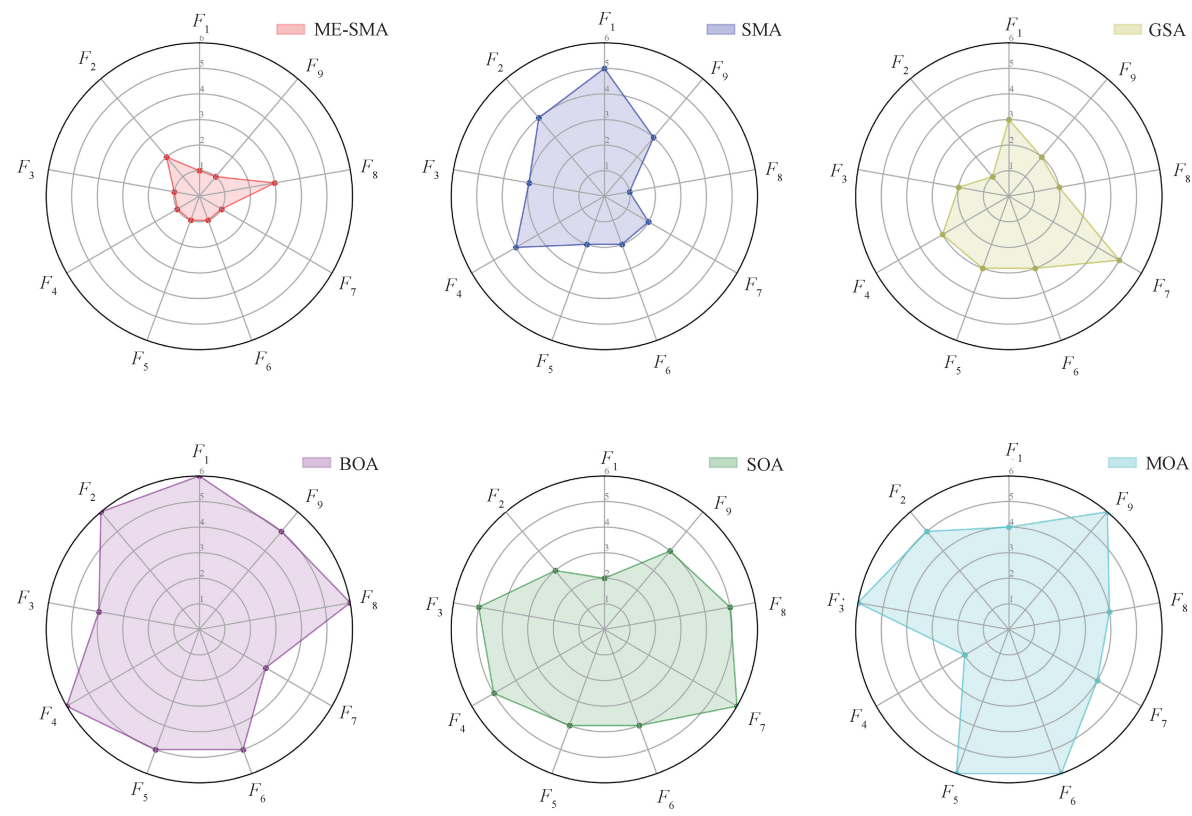


图 7 各算法在测试函数上的雷达图

Fig. 7 Radar chart of each algorithm on the test function

表 3 测试函数实验结果

Table 3 Experimental results of test functions				
函数	算法	最优值	平均值	标准差
单峰函数				
F_1	ME-SMA	1.89×10^{-6}	0.007	0.012 8
	SMA	28.79	28.95	0.131
	GSA	3.56×10^{-5}	0.012 5	0.019 7
	BOA	28.8	28.9	0.023 5
	SOA	1.95×10^{-6}	2.510	7.109
	WOA	26.08	27.47	0.781
F_2	ME-SMA	1.74×10^{-6}	4.61×10^{-4}	6.07×10^{-4}
	SMA	0.097 3	0.338	0.197
	GSA	5.52×10^{-9}	2.13×10^{-4}	3.18×10^{-4}
	BOA	2.81	4.50	0.629
	SOA	5.97×10^{-4}	7.74×10^{-3}	0.066
	WOA	0.436	1.020	0.538
F_3	ME-SMA	3.20×10^{-6}	4.11×10^{-4}	3.78×10^{-4}
	SMA	1.76×10^{-6}	8.73×10^{-4}	8.62×10^{-4}
	GSA	7.31×10^{-6}	3.97×10^{-4}	3.44×10^{-4}
	BOA	4.37×10^{-5}	5.51×10^{-4}	5.51×10^{-4}
	SOA	9.07×10^{-5}	8.40×10^{-4}	5.52×10^{-4}
	WOA	1.58×10^{-3}	0.002 03	0.015
多峰函数				
F_4	ME-SMA	0	3.67×10^{-6}	1.10×10^{-5}
	SMA	4.9×10^{-10}	7.38×10^{-3}	0.038 8
	GSA	2.2×10^{-11}	3.94×10^{-4}	0.002 07
	BOA	181.971	236.281	21.330
	SOA	6.70×10^{-3}	22.283	33.969
	WOA	2.8×10^{-13}	4.31×10^{-7}	2.30×10^{-6}
F_5	ME-SMA	4.4×10^{-16}	4.4×10^{-16}	0
	SMA	4.4×10^{-16}	4.4×10^{-16}	0
	GSA	4.4×10^{-16}	4.4×10^{-16}	0
	BOA	0.011 6	0.013 13	7.40×10^{-4}
	SOA	4.4×10^{-16}	5.6×10^{-16}	6.4×10^{-16}
	WOA	0.021 2	1.271 7	3.603
F_6	ME-SMA	0	0	0
	SMA	0	0	0
	GSA	0	0	0
	BOA	3.13×10^{-3}	3.91×10^{-3}	4.52×10^{-4}
	SOA	0	0	0
	WOA	3.85×10^{-3}	0.239 2	0.168
固定维多峰函数				
F_7	ME-SMA	0.998	0.998	9.8×10^{-14}
	SMA	0.998	0.998	8.46×10^{-7}
	GSA	0.998	1.197	0.538
	BOA	0.998	1.104	0.238
	SOA	0.998	2.535	2.950
	WOA	0.998	1.296	0.472
F_8	ME-SMA	-3.281	-3.163	0.262
	SMA	-3.322	-3.282	0.054
	GSA	-3.318	-3.08	0.138
	BOA	-2.667	-1.711	0.493
	SOA	-3.197	-2.736	0.428
	WOA	-3.251	-2.86	0.453
F_9	ME-SMA	-10.536 28	-10.534 69	0.022 3
	SMA	-10.536 34	-5.665 9	2.583 7
	GSA	-10.536 35	-10.534 77	0.002 1
	BOA	-9.729 97	-5.354 17	1.175 8
	SOA	-10.536 32	-8.750 9	2.777 5
	WOA	-8.339 53	-3.695 96	1.670 71

名的雷达图。从图 7 可以看出,代表 ME-SMA 算法性能的区域面积最小,而 BOA 算法的区域面积最大。这直观地表明,融合了 3 种优化策略的 ME-SMA 算法在综合性能上相比其他对比算法有显著提升,进一步凸显了其优越性。

4 全局路径规划实验结果及分析

4.1 实验设置

1) 栅格地图建模

路径规划区域从可视化地图中进行提取。对地图进行处理时,为了从原始彩色图划分出可通行区域与障碍物区域,首先将地图进行灰度化处理,通过式(15)将彩色图 $M_c[(R,G,B)_{(x,y)}]$ 转换为灰度图 $M_g[g_{(x,y)}]$ 。

$$g_{(x,y)} = (\omega_1, \omega_2, \omega_3) \cdot (R, G, B)_{(x,y)} \tag{15}$$

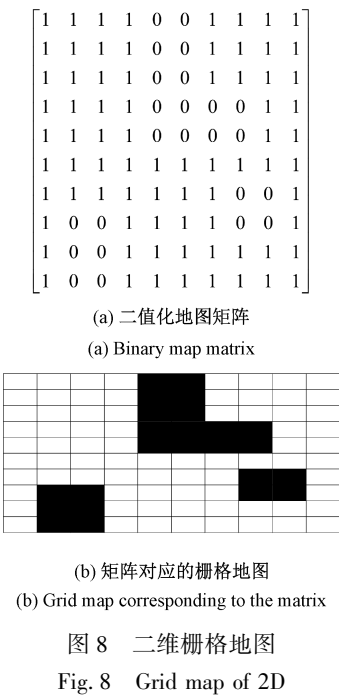
式中: R, G, B 分别表示红、绿、蓝 3 种颜色通道的值; ω 是通过加权平均法初始化地图灰度的颜色权重。

得到灰度化地图后,通过式(16)将灰度图二值化。

$$g'_{(x,y)} = \begin{cases} 0, & g_{(x,y)} < \theta \\ 255, & g_{(x,y)} \geq \theta \end{cases} \tag{16}$$

式中: θ 是事先设定的阈值。

将经过灰度化和二值化的地图保存至二维矩阵中,用数字“0”表示障碍物区域,数字“1”表示可通航区域,便可将原始地图转换为仅包含可通行区域(白色)和障碍物区域(黑色)的栅格地图。 10×10 的二值化地图矩阵和其对应的栅格地图如图 8 所示。



2) 行走方式

SMA 初期寻找路径的过程中随机性较大,使得算法初期的搜索速度降低。因此,为解决算法初期收敛速度慢和具有盲目性的问题,采取八叉树方法,与引导函数和轮盘赌策略相结合以生成部分初始化种群,生成部分次优解。八叉树行走方式如图 9 所示。

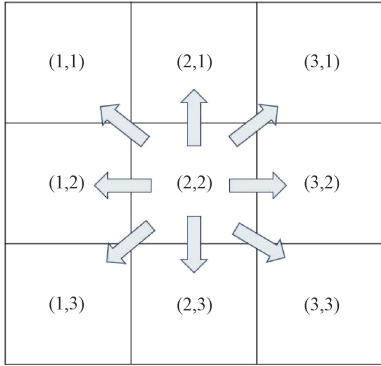


图 9 八叉树行走方式
Fig. 9 Octree walking style

算法可以选择 8 个行走方向,因其存在斜行方式,所以相较于只有 4 个方向的四叉树行走方式,该方法形成的路径更短,所以选用八叉树的行走方式。从初始栅格出发,按八叉树原则,选取与栅格相邻的自由栅格作为待选路径栅格,然后计算引导函数的值,引导函数如式(17)所示。

$$F(x_i, y_i) = \frac{1}{\sqrt{(x_i - x_e)^2 + (y_i - y_e)^2}} \tag{17}$$

式中: (x_i, y_i) 为自由栅格; (x_e, y_e) 为目标栅格。将自由栅格的引导因子计算后,使用赌盘策略选择下一个栅格。在一条路径中,当栅格被选定后,标记该栅格,在后续路径规划中不会被再次选择,以避免产生循环路径。

为了保证初始种群的多样性,使用八叉树策略生成的个体数量占最大种群数量的 10%,剩下个体生成使用混沌映射方案。

3) 平滑处理

最终迭代生成的路径由一定数量的路径点组成,其中有一些路径点是冗余的,甚至是不必要的,这些路径点的存在会增加路径长度和转向次数。因此,采用相应的删除策略将这些路径点删除。该操作在缩短路径长度的同时,还减少了船舶转向点,提高了路径的可行性。

删除策略的具体操作如下:若相邻的几个路径点在同一条直线上,则删除这几个点构成的线段的除端点之外的路径点,如图 10 所示,节点 2、3、4 在同一直线上,则删除节点 3;若路径附近没有障碍物,路径却出现了转折,删除转向点后,其相邻的两个路径点相连所得到的新的路径是可行的,则删除此转向点,图 10 中,删除节点 4

后得到的新的路径是可行的,则删除节点 4。

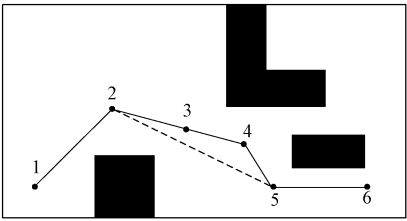


图 10 删除策略
Fig. 10 Delete policy

为了使最终所规划的路径更具有实用性,对应用删除算子之后的路径进行平滑处理,避免路径中出现尖角转弯,最终得到一条较为平滑的规划路径。本文中使用三次样条插值进行平滑曲线拟合,其原理如下:假设有 n 个点 $\{(x_i, y_i), i = 1, 2, \dots, n\}$, $x_1 < x_2 < \dots < x_n$, 求 $S(x)$ 使得 $S(x)$ 有连续二阶导数并且 $S(x)$ 通过 n 个点,即求 $S(x)$ 使其满足式(18)的函数就是三次样条函数。

$$\begin{cases} S(x_i) = y_i, i = 1, 2, \dots, n \\ \min \int |S''(x)|^2 dx \end{cases} \tag{18}$$

三次样条插值使得每个分割区间 $[x_i, x_{i+1}]$ 内, $S(x)$ 都由一个三次多项式来表示,最终得到一条平滑的曲线且每个点都被某段插值函数穿过。原始曲线与平滑后的曲线对比示意图如图 11 所示。

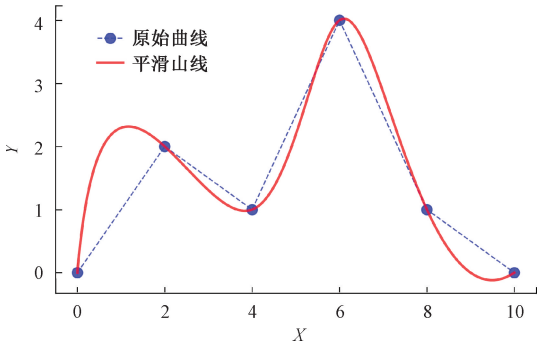


图 11 三次样条平滑曲线示意图
Fig. 11 Schematic diagram of cubic spline smooth curve

4.2 实验结果及分析

1) 栅格环境路径规划实验

为了进一步验证改进算法的有效性,本文分别设置了 50×50 的简单栅格环境、 100×100 的复杂栅格环境和一幅某海域地图进行对比试验,将路径平滑后的 ME-SMA 与未进行路径平滑的 ME-SMA、GSA、GA 进行对比分析,测试几种算法在不同地图中的表现。3 种算法以及含有平滑处理的 ME-SMA 在地图中规划出的轨迹路线如图 12、13 所示。由于在实验地图中,几种算法所规划的路径有部分重叠,实验结果以及数据处理后结果如表

4~7 所示。表 4、6 为实验中的路径数据以验证实验结果的正确性,其中加粗项分别为图 12、13 中各算法对应的路径数据。

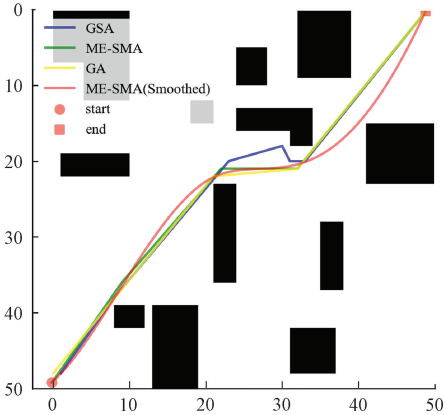


图 12 50×50 环境下的全局路径规划结果
Fig. 12 Path planning results in a 50×50 environment

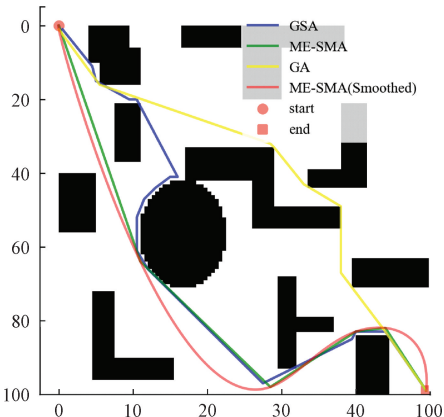


图 13 100×100 环境下的全局路径规划结果
Fig. 13 Path planning results in a 100×100 environment

将每种算法在 3 张地图中分别进行 10 次独立求解,然后计算各算法的最优值、平均值和标准差对有效性进行判别。表 5、7 分别是表 4、6 中的实验数据处理后得到的结果,各地图中数据处理后的最优结果已在表中加粗展示。

在简单地图场景下,由图 12 和表 4、5 可知,ME-SMA 得到的规划路径长度均低于另外两种算法的规划结果,ME-SMA 规划路径长度平均值与 GA 相比减少 1.7%,与 GSA 相比减少 3.2%,稳定性与 GA 相比提高了 30.6%,与 GSA 相比提高了 51.7%。这一结果表明,ME-SMA 在简单环境中不仅能快速收敛到更优路径,且算法稳定性更优。相比之下,平滑后的 ME-SMA 虽然路径长度均值和标准差波动幅度有所增加,但经过删除操作和平滑操作后产生了路径长度的最优值,反映出平滑策略的有效性。

表 4 50×50 环境下算法性能对比

Table 4 Algorithm performance in 50 × 50 environment

实验次数	平滑后 ME-SMA	未处理 ME-SMA	GA	GSA
1	73.201	71.885	72.267	73.332
2	70.412	70.701	71.939	72.534
3	71.989	71.987	72.765	74.154
4	73.851	71.661	73.381	76.630
5	71.989	71.987	73.872	73.873
6	71.104	70.790	71.357	73.313
7	72.268	71.794	72.259	72.786
8	72.833	72.187	73.444	74.174
9	72.065	71.225	72.998	73.917
10	71.919	70.965	73.336	74.366

表 5 50×50 环境下仿真结果分析

Table 5 Analysis of simulation results in 50×50 environment

算法	最优值	平均值	标准差
平滑后 ME-SMA	70.412	72.163 1	0.983 412
未处理 ME-SMA	70.701	71.518 2	0.548 526
GA	71.357	72.761 8	0.789 863
GSA	72.534	73.907 9	1.134 518

在复杂地图场景中,由图 13 和表 6、7 可知,ME-SMA 得到的规划路径长度均低于另外两种算法的规划结果,ME-SMA 规划路径长度平均值与 GA 相比有些许增加,与 GSA 相比减少了 4.6%,稳定性与 GA 相比提高了 62.3%,与 GSA 相比提高了 2.7%。虽然 ME-SMA 的规划路径长度均值劣于 GA,但其标准差低至 5.419 668,成为标准差最优算法。这表明该算法在复杂拓扑中虽然路径质量有所下降,但仍然可以保持较好的稳定性。GA 算法在复杂场景中表现异常突出,平均路径长度达到 174.428 1,标准差为 17.651 4,其最优值 150.603 甚至优于平滑后 ME-SMA 的 174.804。通过对最短路径的研究,发现这一反常现象是规划路线与障碍物的距离过近造成的,不利于船舶安全航行,同时这也暴露出 GA 收敛过程的不稳定性。GSA 在复杂场景中表现最弱,表明其在复杂约束下易陷入局部最优,且算法收敛精度不足。

表 6 100×100 环境下算法性能对比

Table 6 Algorithm Performance in 100 × 100 environment

实验次数	平滑后 ME-SMA	未处理 ME-SMA	GA	GSA
1	174.804	170.841	150.603	185.335
2	186.645	180.569	190.828	179.512
3	193.428	182.224	181.242	180.562
4	175.500	171.919	151.967	195.239
5	176.575	173.758	183.966	181.464
6	189.986	178.401	155.978	183.925
7	175.996	172.528	191.609	187.997
8	187.406	182.466	159.854	194.350
9	193.284	186.162	193.920	188.164
10	177.292	173.166	184.314	181.677

表 7 100×100 环境下仿真结果分析

算法	最优值	平均值	标准差
平滑后 ME-SMA	174. 804	183. 091 6	7. 762 197
未处理 ME-SMA	170. 841	177. 203 4	5. 419 668
GA	150. 603	174. 428 1	17. 651 42
GSA	179. 512	185. 822 5	5. 568 911

由实验结果可以看出,简单环境中,ME-SMA 求解规划问题时有良好的优越性和稳定性,经平滑处理后的结果稳定性有所下降。复杂环境中,ME-SMA 不仅成功规避了障碍物,而且选择了最优路线以更小的代价到达目的点,且有着不错的鲁棒性。

2) 海上全局路径规划仿真试验

海上全局路径规划仿真试验实验路径规划效果图如图 14 所示。该仿真试验数据如表 8 和 9 所示。各算法性能差异进一步放大。3 项指标均是 ME-SMA 占优。ME-SMA 规划路径长度平均值与 GA 相比减少 1. 08%,与 GSA 相比减少 1. 8%,稳定性与 GA 相比提高了 4. 69%,与 GSA 相比提高了 17. 33%。平滑后 ME-SMA 以 900. 051 1 的平均值和 13. 079 0 的标准差成为海上全局路径规划仿真试验中的最优选择,其路径长度均值较未处理 ME-SMA 的 918. 619 9 缩短了 2. 02%,凸显了平滑策略在海上全局路径规划中的有效性。GA 在该场景中表现疲软,其标准差 20. 827 36 虽接近 ME-SMA,但平均路径长度达 928. 658,劣于 ME-SMA。GSA 算法在该场景中表现最差,平均路径长度为 936. 133 6,标准差 24. 011 4,表明该算法在该试验环境中收敛精度不足,且算法抗干扰能力较弱。

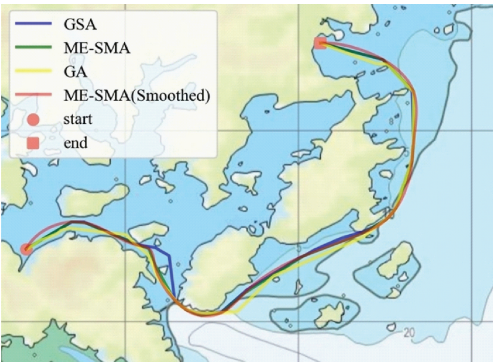


图 14 海上全局路径规划仿真路径示意图

Fig. 14 Global path planning results in test environment

从以试验结果可以看出,在海上全局路径规划仿真中,ME-SMA 的稳定性有更显著的表现。3 个测试环境中,平滑操作或许会使路径长度有些许增大,但对比其他两种算法,仍有明显的优势。

表 8 海上全局路径规划仿真各算法性能对比

实验次数	平滑后 ME-SMA	未处理 ME-SMA	GA	GSA
1	901. 696	933. 856	926. 881	985. 803
2	922. 588	952. 924	951. 366	930. 116
3	889. 829	902. 434	970. 913	911. 42
4	922. 606	945. 229	922. 773	958. 108
5	899. 8	922. 718	909. 94	927. 871
6	896. 618	911. 56	921. 511	922. 857
7	888. 747	900. 475	905. 539	939. 279
8	887. 381	898. 385	910. 558	914. 143
9	889. 445	899. 587	922. 287	915. 207
10	901. 801	919. 031	944. 812	956. 532

表 9 海上全局路径规划仿真结果

Table 9 Analysis of simulation results in test environment

算法	最优值	平均值	标准差
平滑后 ME-SMA	887. 381	900. 051 1	13. 079 02
未处理 ME-SMA	898. 385	918. 619 9	19. 851 34
GA	905. 539	928. 658	20. 827 36
GSA	911. 42	936. 133 6	24. 011 42

平滑后 ME-SMA 通过引入路径平滑策略,在保留原始 ME-SMA 全局搜索能力的同时,有效抑制了路径振荡现象,使其在各类场景中均能保持较高的路径质量。未处理 ME-SMA 缺乏平滑机制,导致路径曲折度增加。GA 凭借其种群多样性优势,在复杂场景中可通过交叉变异跳出局部最优,但标准差的剧烈波动暴露出其收敛过程的不稳定性。GSA 在复杂路径空间中易陷入早熟收敛,导致在海上全局路径规划仿真中性能显著下降。

综上,平滑后 ME-SMA 凭借其均衡的全局搜索能力与路径平滑策略,在试验中表现出最优的综合性能,充分体现了 ME-SMA 用于全局路径规划的可行性和合理性。

5 结 论

为提升 SMA 在路径规划中的性能,本文提出了一种 ME-SMA 算法。通过改进 Logistic 混沌映射优化种群初始化,结合遗传算法的交叉、变异及选择操作增强全局搜索能力,并引入黄金正弦策略避免早熟收敛。实验结果表明,ME-SMA 在测试函数优化及复杂路径规划任务中展现出更优的收敛精度、鲁棒性和计算效率。

首先利用改进 Logistic 混沌映射对黏菌种群进行初始化,其遍历性特点有效避免了传统随机初始化导致的种群分布不均问题。混沌初始化策略使初始种群分布均匀性提升,较随机初始化更为分散,为后续全局寻优奠定了基础,降低了算法陷入局部最优的风险。其次在算法迭代过程中,引入遗传算法的交叉、变异与选择机制,通

过精英个体引导种群向高适应度区域收敛,加快算法的收敛速度。然后将黄金正弦策略融入黏菌位置更新过程,利用正弦函数的非线性搜索特性动态调整搜索方向,结合黄金分割系数缩小搜索空间,平衡算法的全局探索与局部开发能力。在路径规划实验中,ME-SMA 在测试地图中规划的路径综合效果更好,平滑处理后路径连续性更优。此外,八叉树引导策略与轮盘赌选择的结合进一步提升了初始种群的多样性,使算法在复杂障碍环境中仍能保持高效寻优能力。

尽管 ME-SMA 在基准函数测试和 USV 全局路径规划任务中表现出了优异的性能,但仍存在一些不足之处,比如有动态目标环境下全局路径规划、自然条件(风、浪、流等)对路径规划的影响等考虑不足等,未来的工作还需要结合 USV 动态避碰和海上实船试验进一步完善和探索结合全局和局部路径的规划,并结合实船试验验证复杂海况下本本文提出的全局路径规划的实际效能。

参考文献

- [1] 邢博闻,杨柳,胡庆松,等. 无人船全覆盖路径规划算法研究[J]. 兵器装备工程学报, 2022, 43(9): 28-33.
- XING B W, YANG L, HU Q S, et al. Research of unmanned ship based on artificial bee colony method[J]. Journal of Ordnance Equipment Engineering, 2022, 43(9): 28-33.
- [2] 李勇航,单晨晨,苏明,等. 声学水面无人艇在浅水海底地貌调查中的应用[J]. 海洋地质与第四纪地质, 2020, 40(6): 219-226.
- LI Y H, SHAN CH CH, SU M, et al. Application of acoustic unmanned surface vehicle to submarine geomorphology survey in shallow water[J]. Marine Geology and Quaternary Geology, 2020, 40(6): 219-226.
- [3] LIU W J, FENG H H, WANG B F, et al. Numerical study of unmanned surface vessel's dynamic characteristics in rough sea conditions[J]. Ocean Engineering, 2025, 333(1): 121386.
- [4] 王涵宇. 无人水面艇导航技术研究[J]. 舰船科学技术, 2023, 45(11): 94-97.
- WANG H Y. Research on navigation technology and methods of autonomous unmanned vehicle[J]. Ship Science and Technology, 2023, 45(11): 94-97.
- [5] 徐筱波,叶锴,王登峰. 无人水面艇关键技术及军事应用[J]. 广东造船, 2023, 42(4): 35-38.
- XU X B, YE K, WANG D F. Key technologies and military applications of USV[J]. Guangdong Shipbuilding, 2023, 42(4): 35-38.
- [6] 白响恩,孙广志,徐笑锋. 基于改进粒子群算法的河流环境下无人水面艇路径规划[J]. 上海海事大学学报, 2023, 44(4): 1-7.
- BAI X EN, SUN G ZH, XU X F. Path planning of unmanned surface vessels in ocean current environment based on improved particle swarm optimization algorithm[J]. Journal of Shanghai Maritime University, 2023, 44(4): 1-7.
- [7] 刘祥,叶晓明,王泉斌,等. 无人水面艇局部路径规划算法研究综述[J]. 中国舰船研究, 2021, 16(S1): 1-10.
- LIU X, YE X M, WANG Q B, et al. Review on the research of local path planning algorithms for unmanned surface vehicles[J]. Chinese Journal of Ship Research, 2021, 16(S1): 1-10.
- [8] 杨国,吴晓,肖如奇,等. 改进 A* 算法的安全高效室内全局路径规划[J]. 电子测量与仪器学报, 2024, 38(7): 131-142.
- YANG G, WU X, XIAO R Q, et al. Improved A* algorithm for secure and efficient indoor global path planning[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 131-142.
- [9] SUN Y H, FANG M, SU Y X. AGV Path planning based on improved Dijkstra algorithm[J]. Journal of Physics: Conference Series, 2021, 1746(1): 012052.
- [10] 左秀峰,沈万杰. 基于 Floyd 算法的多重最短路问题的改进算法[J]. 计算机科学, 2017, 44(5): 232-234, 267.
- ZUO X F, SHEN W J. Improved algorithm about multi-shortest path problem based on floyd algorithm[J]. Computer Science, 2017, 44(5): 232-234, 267.
- [11] AIRLANGGA G, SUKWADI R, BASUKI W W, et al. Adaptive path planning for multi-UAV systems in dynamic 3D environments: A multi-objective framework[J]. Designs, 2024, 8(6): 136.
- [12] 程细得,刘鹏辉,韩琨羽,等. 基于人工势场-操纵运动混合模型的船舶路径规划[J]. 华中科技大学学报(自然科学版), 2024, 52(1): 85-90.
- CHENG X D, LIU P H, HAN K Y, et al. Path planning of ship based on artificial potential field-maneuvering motion hybrid model[J]. J. Huazhong Univ. of Sci. & Tech. (Natural Science Edition), 2024, 52(1): 85-90.
- [13] 张乃天,陈世才,蒙子昕. 基于改进快速行进法的水面无人船全局路径规划[J]. 上海海事大学学报, 2023, 44(3): 5-11.
- ZHANG N T, CHEN SH C, MENG Z X. Global path planning of unmanned surface vehicles based on improved fast marching method[J]. Journal of Shanghai Maritime University, 2023, 44(3): 5-11.
- [14] WANG Q Y, XU M H, HU Z Y. Path planning of

- unmanned aerial vehicles based on an improved bio-inspired tuna swarm optimization algorithm [J]. *Biomimetics*, 2024, 9(7): 388.
- [15] YANG Y, HUANG T, WANG T, et al. Sampling-efficient path planning and improved actor-critic-based obstacle avoidance for autonomous robots [J]. *Science China (Information Sciences)*, 2024, 67(5): 197-214.
- [16] 陈敏. 基于采样算法的移动机器人路径规划[D]. 广州:广东工业大学, 2019.
- CHEN M. Mobile robot path planning based on sampling algorithm [D]. Guangzhou: Guangdong University of Technology, 2019.
- [17] 王梓强, 胡晓光, 李晓筱, 等. 移动机器人全局路径规划算法综述[J]. *计算机科学*, 2021, 48(10): 19-29.
- WANG Z Q, HU X G, LI X Y, et al. Overview of global path planning algorithms for mobile robots[J]. *Computer Science*, 2021, 48(10): 19-29.
- [18] 李薪颖, 单梁, 常路, 等. 复杂环境下基于多目标粒子群的 DWA 路径规划算法[J]. *国防科技大学学报*, 2022, 44(4): 52-59.
- LI X Y, SHAN L, CHANG L, et al. DWA path planning algorithm based on multi-objective particle swarm optimization in complex environment [J]. *Journal of National University of Defense Technology*, 2022, 44(4): 52-59.
- [19] 邓冬冬, 许建民, 孟寒, 等. 基于蚁群算法与人工势场法融合的移动机器人路径规划[J]. *仪器仪表学报*, 2025, 46(2): 1-16.
- DENG D D, XU J M, MENG H, et al. Mobile robot path planning based on the fusion of ant colony algorithm and artificial potential field method[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(2): 1-16.
- [20] 陈丽芳, 杨火根, 陈智超, 等. B 样条技术与遗传算法融合的全局路径规划 [J]. *浙江大学学报: 工学版*, 2024, 58(12): 2520-2530.
- CHEN L F, YANG H G, CHEN ZH CH, et al. Global path planning with integration of B-spline technique and genetic algorithm [J]. *Journal of Zhejiang University (Engineering Science)*, 2024, 58(12): 2520-2530.
- [21] 李晓旭, 马兴录, 王先鹏. 移动机器人路径规划算法综述[J]. *计算机测量与控制*, 2022, 30(7): 9-19.
- LI X X, MA X L, WANG X P. A Survey of path planning algorithms for mobile robots [J]. *Computer Measurement and Control*, 2022, 30(7): 9-19.
- [22] PATHAK V K, GANGWAR S, DIKSHIT M K. A comprehensive survey on seagull optimization algorithm and its variants[J]. *Archives of Computational Methods in Engineering*, 2025, 1(1): 1-35.
- [23] XU T, CHEN C Y. DBO-AWOA: An adaptive whale optimization algorithm for global optimization and UAV 3D path planning[J]. *Sensors*, 2025, 25(7): 2336.
- [24] YILDIRIM M Y, AKAY R. An efficient grid-based path planning approach using improved artificial bee colony algorithm [J]. *Knowledge-Based Systems*, 2025, 318(1): 113528.
- [25] 乐明皓, 李凌. 多策略融合的改进麻雀搜索算法及其 AGV 路径规划应用[J]. *国外电子测量技术*, 2024, 43(7): 129-139.
- LE M H, LI L. Improved sparrow search algorithm with multi strategy fusion and application in AGV path planning [J]. *Foreign Electronic Measurement Technology*, 2024, 43(7): 129-139.
- [26] 宋宇, 高岗, 梁超, 等. 基于多策略改进灰狼算法的无人机路径规划[J]. *电子测量技术*, 2025, 48(1): 84-91.
- SONG Y, GAO G, LIANG CH, et al. UAV path planning based on multi-strategy improved gray wolf algorithm [J]. *Electronic Measurement Technology*, 2025, 48(1): 84-91.
- [27] EHSAEYAN E, ZOLGHADRASLI A. FOA: Fireworks optimization algorithm [J]. *Multimedia Tools and Applications*, 2022, 81(23): 33151-33170.
- [28] LI S M, CHEN H L, WANG M J, et al. Slime mold algorithm: A new method for stochastic optimization[J]. *Future Generation Computer Systems*, 2020, 111(1): 300-323.
- [29] ZHENG L, HONG C Z, SONG H S, et al. An autonomous mobile robot path planning strategy using an enhanced slime mold algorithm [J]. *Frontiers in Neurorobotics*, 2023, 17(1): 1270860.
- [30] 刘美娇. 空间超冗余四足爬行机器人轨迹规划方法研究[D]. 长春:中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2022.
- LIU M J. Research on trajectory planning method of spatial hyper-redundant quadruped crawling robot [D]. Changchun: University of Chinese Academy of Sciences (Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, China), 2022.
- [31] 张鑫强, 邱一卉, 李若玉. 基于改进黏菌算法的特征选择方法[J]. *厦门大学学报(自然科学版)*, 2024, 63(3): 550-561.
- ZHANG X Q, QIU Y H, LI R Y. Feature selection method based on improved slime mould algorithm[J]. *Journal of Xiamen University (Natural Science)*, 2024, 63(3): 550-561.

[32] ZHANG Y J, WANG Y F, YAN Y X, et al. Self-adaptive hybrid mutation slime mould algorithm: Case studies on UAV path planning, engineering problems, photovoltaic models and infinite impulse response [J]. Alexandria Engineering Journal, 2024, 98 (1): 364-389.

[33] HOUSSEIN E H, MAHDY M A, BLONDIN M J, et al. Hybrid slime mould algorithm with adaptive guided differential evolution algorithm for combinatorial and global optimization problems [J]. Expert Systems with Applications, 2021, 174(1): 114689.

[34] HASSAN M H, KAMEL S, ABUALIGAH L, et al. Development and application of slime mould algorithm for optimal economic emission dispatch[J]. Expert Systems with Applications, 2021, 128(1): 115205.

[35] SAMANTARAY S, SAHOO P, SAHOO A, et al. Flood discharge prediction using improved ANFIS model combined with hybrid particle swarm optimisation and slime mould algorithm [J]. Environmental Science and Pollution Research International, 2023, 30(35): 83845-83872.

[36] CHAKRABORTY P, NAMA S, SAHA A K. A hybrid slime mould algorithm for global optimization [J]. Multimedia Tools and Applications, 2021, 82 (15): 22441-22467.

[37] CHAUHAN S, VASHISHTHA G, KUMAR A. A symbiosis of arithmetic optimizer with slime mould algorithm for improving global optimization and conventional design problem [J]. The Journal of Supercomputing, 2021, 78(5): 6234-6274.

[38] XIONG W Q, ZHU D L, LI R, et al. An effective method for global optimization-Improved slime mould algorithm combine multiple strategies [J]. Egyptian

Informatics Journal, 2024, 25(1): 100442.

[39] OLMEZ Y, KOCA G O, SENGUR A, et al. Chaotic opposition golden sinus algorithm for global optimization problems [J]. Chaos, Solitons and Fractals: The interdisciplinary journal of Nonlinear Science, and Nonequilibrium and Complex Phenomena, 2024, 183(1): 114869.

[40] 魏博, 汤荣杰, 郑英豪, 等. 基于改进蝴蝶优化算法的机器人路径规划 [J]. 北京工业大学学报, 2025, 51(3): 295-307.

WEI B, TANG R J, ZHENG Y H, et al. Improved butterfly optimization algorithm for mobile robot path planning [J]. Journal oof Beijing University of Technology, 2025, 51(3): 295-307.

作者简介



刘金科,2024 年于集美大学获得学士学位,现为集美大学硕士研究生,主要研究方向为无人船路径规划。

E-mail: 202411823023@jmu.edu.cn

Liu Jinke received his B. Sc. degree from Jimei University in 2024. He is now a M.Sc. candidate at Jimei University. His main research interest includes path planning for USV.



周世波 (通信作者),2018 年于北京交通大学获得博士学位,现为集美大学航海学院教授,主要研究方向为数据挖掘、无人船路径规划、系统分析与集成。

E-mail: zhoushibo@jmu.edu.cn

Zhou Shibo (Corresponding author) received his Ph. D. degree from Beijing Jiaotong University in 2018. He is now a professor at Jimei University. His main research interests include data mining, Path planning for USV and system analysis and integration.