

基于多策略融合灰狼算法的移动机器人路径规划

黄琦, 陈海洋, 刘妍, 都威

(西安工程大学电子信息学院, 西安, 710048)

摘要 针对标准灰狼算法(GWO)在解决移动机器人路径规划问题时存在初始参数依赖性强、缺乏多样性及易陷入局部极值的缺陷,提出一种基于多策略融合灰狼算法(LTGWO)。首先运用精英化思想将 Logistic-Tent 复合混沌映射与反向学习结合,优化灰狼种群分布序列;然后引入 sigmoid 函数修改收敛因子 a ,平衡算法全局探索与局部开发能力,并改进控制参数 C 以更好地拟合灰狼实际捕猎过程;最后加入随适应度值变化的比例权重,提高灰狼个体搜索能力,同时采用种群淘汰策略,淘汰适应度值差的个体,促进种群进化。选用3组不同的栅格地图进行实验,实验结果表明:由 LTGWO 算法生成的平均路径长度、路径长度标准差都优于对比算法。

关键词 路径规划;灰狼算法;移动机器人;精英反向学习;Logistic-Tent 复合混沌映射;种群淘汰

DOI 10.3969/j.issn.2097-1915.2024.03.016

中图分类号 TP312 **文献标志码** A **文章编号** 2097-1915(2024)03-0112-09

A Mobile Robot Path Planning Based on Multi-Strategy Fusion Gray Wolf Algorithm

HUANG Qi, CHEN Haiyang, LIU Yan, DU Wei

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract Aimed at the problems that robot path planning problems being solved by the standard gray wolf algorithm, initial parameters are strong in dependence, lack of variety, and liable to sink into local extreme value, a Logistic-Tent based Grey Wolf Optimizer (LTGWO) is proposed. Firstly, by an elite method, the Logistic-Tent composite chaotic mapping is in combination with inverse learning to improve the population distribution. And then, by introducing the sigmoid function, the factor of concentration and balances between global exploration and local exploitation is adjusted, while the improved control parameters are fitted even more in line with the actual hunting behavior. Lastly, Proportional weights being in company with the changes of adaptable value are added to enhance the search ability of individual gray wolves. A population culling strategy is adopted to eliminate the individuals with poor fitness, promoting evolution. Three different groups of raster maps are selected for the experiments, and the experimental results show that the average path length and the standard deviation of the path length generated by the LTGWO algorithm are better than the comparison algorithm.

Key words path planning; gray wolf algorithm; mobile robots; elite backward learning; Logistic-Tent compound chaotic map; population culling

收稿日期: 2023-12-23

基金项目: 国家自然科学基金(51905405)

作者简介: 黄琦(1994-),男,福建龙岩人,硕士生,研究方向为人工智能。E-mail: qih94815@163.com

通信作者: 陈海洋(1967-),男,陕西西安人,副教授,博士,研究方向为人工智能、先进控制理论及其应用。E-mail: chy_00@163.com

引用格式: 黄琦,陈海洋,刘妍,等.基于多策略融合灰狼算法的移动机器人路径规划[J].空军工程大学学报,2024,25(3):112-120.
HUANG Qi, CHEN Haiyang, LIU Yan, et al. A Mobile Robot Path Planning Based on Multi-Strategy Fusion Gray Wolf Algorithm[J]. Journal of Air Force Engineering University, 2024, 25(3): 112-120.

近年来,随着移动机器人在众多领域,如自动驾驶、军事作战、医疗保健和救援等的应用不断扩大^[1],路径规划已经逐渐成为移动机器人研究中至关重要的一环。路径优化算法是路径规划的核心要素^[2],依据不同的理论基础,可以将移动机器人的路径优化算法分成几个主要类别:搜索导向的路径规划算法^[3]、依赖采样的路径规划算法、基于模型的路径规划算法、借鉴生物启发原理算法^[4]等。相较于传统规划算法,生物启发式算法具有更强的全局探索能力、更好的自适应性。生物启发式算法包括灰狼算法(grey wolf optimization, GWO)^[5]、鱼鹰优化算法(osprey optimization algorithm, OOA)^[6]、斑马优化算法(zebra optimization algorithm, ZOA)^[7]、霸王龙算法(tyrannosaurus optimization, TROA)^[8]、免疫算法(immune algorithm, IA)^[9]等。其中灰狼算法是一种新兴的生物启发式优化算法,具有适应性强、控制参数少、鲁棒性高、容易编码实现等优点,在电力系统故障诊断^[10]、光伏能源优化^[11]、建筑能耗优化^[12]、滑坡位移预测^[13]、汽车自动驾驶^[14]等不同领域中有广泛的应用。

标准 GWO 算法存在初始参数依赖性强、全局探索与局部开发不平衡、收敛精度低等问题,这使得 GWO 算法在解决移动机器人路径规划时会出现搜索最优路径所需时间长、碰撞概率增加等问题^[15]。为了改善标准 GWO 算法的性能,文献[16]将金鹰优化算法与 GWO 算法相融合,提出混合算法 HGEOGWO,该算法提高了标准 GWO 算法全局探索能力,降低 GWO 算法陷入局部最优的可能性;文献[17]引入 PWLCM 映射策略对种群进行初始化以确保初始个体在搜索空间中的分布尽可能均匀,提高收敛速度;文献[18]对收敛因子 a 提出一种非线性控制参数组合调整策略,使得改进后的灰狼算法前期全局探索能力加强,后期加快算法收敛速度;文献[19]为了增强 GWO 算法的探索性,避免陷入局部最优,提出反学习策略,反学习策略概率使智能体反向移动,当领导者陷入局部最优时,反向移动可以提供再次搜索更好结果的能力。

上述文献提出的改进方法对 GWO 算法的性能都有所提升,但大多数仅侧重于对算法的部分元素进行优化,而忽略了对整体缺陷的系统性改进,易导致算法鲁棒性差、整体性能波动较大。因此,本文提出一种基于多策略融合灰狼算法(logistic-tent based grey wolf optimizer, LTGWO),在种群初始化、全局探索与局部开发、狼群位置更新、种群优化方面进行统筹改进:

1)为提升种群位置分布的多样性,将 Logistic-Tent 复合混沌映射与反向学习结合,优化初始灰狼种群分布序列。

2)引入 sigmoid 函数修改收敛因子 a ,以平衡算法全局探索与局部开发能力。改进控制参数 C ,以增强算法寻优能力。

3)引入随适应度值变化的比例权重改进灰狼位置更新公式,以提高灰狼个体搜索能力。

4)将种群淘汰机制与贪心策略结合,淘汰适应度值最差的解,以促进种群的进化。

1 灰狼算法

Mirjalili 等基于灰狼集体行动的启示,提出 GWO 算法,用来模仿灰狼的层级规则和它们的跟随、包围行动。GWO 算法将灰狼群中的个体分为 4 个阶层: α 、 β 、 δ 、 ω ,其中 α 狼是最高领导者,它代表了当前的最优解决方案; β 狼则作为 α 狼的副手,它代表的是次优解决方案; δ 狼处于 α 狼和 β 狼之下,它代表的是第三优先的解决方案;而 ω 狼在狼群中的等级最低,作为前 3 级狼的备用解决方案。灰狼群进行狩猎时,通常会经历 3 个不同的阶段:首先是追踪并逐渐靠近猎物,其次是包围并迫使猎物停下来,最后才是实施攻击并成功捕获猎物。

假设灰狼种群数为 N ,灰狼捕食狩猎的数学模型可描述如下:

1)追踪、包围行为的数学模型为:

$$\mathbf{X}(i+1) = \mathbf{X}_p(i) - \mathbf{A} \cdot |\mathbf{C} \cdot \mathbf{X}_p(i) - \mathbf{X}(i)| \quad (1)$$

式中: i 为当前的迭代次数; $\mathbf{X}_p(i)$ 为猎物在第 i 轮迭代时的位置向量; $\mathbf{X}(i)$ 为灰狼在第 i 轮迭代时的位置向量; \mathbf{A} 和 \mathbf{C} 为参数,可表示为:

$$\mathbf{A} = 2a\mathbf{r}_1 - a \quad (2)$$

$$\mathbf{C} = 2\mathbf{r}_2 \quad (3)$$

式中: \mathbf{r}_1 、 \mathbf{r}_2 为 $[0,1]$ 之间的随机向量; a 为收敛因子,在迭代过程中从 2 线性减少到 0,更新公式为:

$$a(i) = 2 - \frac{2i}{I_{\max}} \quad (4)$$

式中: $a(i)$ 为 a 在第 i 次迭代的值^[20]。

2)驱使猎物停止移动,同时发起攻击而捕获猎物的数学模型为:

$$\mathbf{X}_1 = \mathbf{X}_\alpha - \mathbf{A}_1 \cdot |\mathbf{C}_1 \cdot \mathbf{X}_\alpha - \mathbf{X}| \quad (5)$$

$$\mathbf{X}_2 = \mathbf{X}_\beta - \mathbf{A}_2 \cdot |\mathbf{C}_2 \cdot \mathbf{X}_\beta - \mathbf{X}| \quad (6)$$

$$\mathbf{X}_3 = \mathbf{X}_\delta - \mathbf{A}_3 \cdot |\mathbf{C}_3 \cdot \mathbf{X}_\delta - \mathbf{X}| \quad (7)$$

$$\mathbf{X}(i+1) = \frac{\mathbf{X}_1(i) + \mathbf{X}_2(i) + \mathbf{X}_3(i)}{3} \quad (8)$$

式中： \mathbf{X}_α 、 \mathbf{X}_β 、 \mathbf{X}_δ 分别为 α 、 β 、 δ 狼的位置向量。式(8)为 ω 狼的位置更新方式。

GWO 算法由 α 、 β 、 δ 狼提供的最优目标信息来指引方向,在此过程中, ω 狼持续进行追踪并更新群体的位置,通过 \mathbf{A} 和 \mathbf{C} 的动态变化,确保灰狼群体能够有效地探索和逼近较优解。

2 多策略融合的灰狼算法

2.1 混沌反向学习策略的种群初始化

2.1.1 初始种群多样化

在 GWO 算法中,初始灰狼群体在解空间中的位置布局对发掘最优路径有关键的影响,标准 GWO 算法初始灰狼群体在解空间中的位置分布采取的是随机分布法,极易出现分布不均的情况,导致收敛速度降低。相比之下,如果初始群体在解空间内分布均匀,那么算法找到最佳路径的可能性将会显著提升。混沌搜索方法具有随机性、全面探索性和无重复性等优势,这些特性使得其在探索解空间方面优于标准 GWO 算法的随机搜索方法。因此,采用混沌搜索能够更有效地提升算法寻找最优解的速度和精确度。本文引入混沌映射对灰狼种群位置分布进行初始化,然而单一混沌映射经常由于自身存在的不足而导致解空间分布并不均匀^[21],因而本文融合 Logistic 混沌映射和 Tent 混沌映射生成 Logistic-Tent 复合混沌映射。该混沌系统融合了 Logistic 系统的复杂动力学特性与 Tent 混沌系统迭代速度快、自相关性强的特点,使得该系统能够在短时间内生成相比于单一混沌系统更多且均匀的随机序列。它的定义为:

$$Z_{i+1} = \begin{cases} (rZ_i(1-Z_i) + (4-r)Z_i/2) \bmod 1, & Z_i < 0.5 \\ (rZ_i(1-Z_i) + (4-r)(1-Z_i)/2) \bmod 1, & Z_i \geq 0.5 \end{cases} \quad (9)$$

式中： Z_{i+1} 为生成的复合混沌序列, $Z_i \in [0,1]$; r 为控制参数, $r \in (0,4)$; \bmod 为取模运算。


将由式(9)生成的 Z_i 代入式(10),进一步生成灰狼个体在搜索区域内的初始解位置序列,表达式为:

$$M_i = X_{i,\max} + Z_i(X_{i,\max} - X_{i,\min}) \quad (10)$$


式中： M_i 为初始化后灰狼个体位置序列; $X_{i,\max}$ 、 $X_{i,\min}$ 分别为对应解空间的上界和下界。

Logistic-Tent 复合混沌映射初始化灰狼种群位置分布的具体过程为:在 $[0,1]$ 内随机生成 1 个初始混沌序列 Z_1 ,然后代入式(9)迭代生成 $i-1$ 个混沌序列,最后将所有生成的 Z_i 代入式(10)生成灰狼种群初始位置序列。

为了验证复合混沌映射的有效性,将标准 GWO 算法的随机值、Logistic 混沌映射与 Logistic-Tent 复合混沌映射在迭代次数为 5 000 时,在 $0 \sim 1$ 内的分布频率进行对比,结果分别如图 1(a)、图 2(a)和图 3(a)所示。可以看出,标准 GWO 算法为随机分布,每个频段分布不一,Logistic 混沌映射在两极分布明显高于其它频段,Logistic-Tent 复合混沌映射分布较为均匀,每个频段的频数相差不大。图 1(b)、图 2(b)和图 3(b)为标准 GWO 算法、Logistic 混沌映射与 Logistic-Tent 复合混沌映射生成的灰狼种群初始位置分布图,可以看出由 Logistic-Tent 复合混沌映射生成的初始解分布更加均匀。




(a)GWO 算法频率直方图




(b)GWO 算法种群分布图

图 1 GWO 算法频率直方图与种群分布图




(a) Logistic 混沌映射频率直方图




(b) Logistic 混沌映射种群分布图

图 2 Logistic 混沌映射频率直方图与种群分布图



(a) Logistic-Tent 复合混沌映射频率直方图



(b) Logistic-Tent 复合混沌映射种群分布图

图 3 Logistic-Tent 复合混沌映射频率直方图与种群分布图

2.1.2 初始种群精英化

为了加快种群收敛速度,采用精英反向学习策略,使得生成的初始种群偏向全局最优解,实现对初始种群质量的提升。标准 GWO 算法随机生成的初始种群位置序列为 $X_n = \{x_1, x_2, \dots, x_n\}$, 其中 n 为种群数量,引入精英反向学习策略后的种群位置序列为 $X_n^* = \{x_1^*, x_2^*, \dots, x_n^*\}$,精英反向种群定义为:

$$X_n^* = rand \cdot (ub + db) - X_n \quad (11)$$

式中: $rand \in (0, 1)$; ub 、 db 分别为搜索区域的上界和下界。

综合以上过程,混沌反向学习策略初始化灰狼种

群位置序列具体过程为:首先在 $[0, 1]$ 内随机生成 1 个初始混沌序列 Z_1 , 将其代入式(10)生成复合混沌初始化种群位置序列 M_i , 然后随机生成初始种群位置序列 $X_n = \{x_1, x_2, \dots, x_n\}$, 将 X_n 代入式(11)生成精英反向种群序列 X_n^* , 最后对 M_i 和 X_n^* 按灰狼个体适应度值进行排序,选择前 n 个优秀个体构成混沌反向精英初始种群序列 X_{n+1}' , 表达式为:

$$X_{n+1}' = \{x_1', x_2', \dots, x_n'\} \quad (12)$$

2.2 控制参数调整

2.2.1 收敛因子 a 的调整策略

根据式(2),GWO 算法的参数 A 对其全局探索和局部开发能力有着重要影响。当 $|A| > 1$ 时,种群会更倾向于全局探索;当 $|A| \leq 1$ 时,种群则更倾向于局部开发。 A 的值随收敛因子 a 的变化而改变,即 GWO 算法的全局探索和局部开发能力受控于 a 的取值, a 随迭代次数的增加,由 2 线性减小到 0。然而在搜索最优值过程中,收敛因子 a 表现出的线性递减状态并不能很好地平衡 GWO 算法的全局探索和局部开发能力,易陷入局部最优。因此本文引入 sigmoid 函数,修改收敛因子 a 递减的过程,并将本文改进的收敛因子 $a_1(i)$ 与文献[22]、[23]改进的收敛因子进行对比,各收敛因子表达式为:

$$a_1(i) = a_{initial} - \frac{a_{initial} - a_{final}}{1 + e^{-10(\frac{i}{I_{max}} - \frac{1}{2})}} \quad (13)$$

$$a_2(i) = 2 - \frac{2i}{I_{max}} \quad (14)$$

$$a_3(i) = a_{initial} - a_{initial} \frac{1}{e - 1} (e^{\frac{i}{I_{max}}} - 1) \quad (15)$$

$$a_4(i) = 2 - 2\sin(\lambda \frac{i}{I_{max}} \pi + \phi) \quad (16)$$

式中: $a_1(i)$ 为本文改进的非线性收敛因子; $a_{initial}$ 和 a_{final} 分别为控制因子的起始值 2 和终值 0; i 为迭代次数; I_{max} 为最大迭代次数; $a_2(i)$ 为标准 GWO 算法的收敛因子; $a_3(i)$ 为文献[22]的收敛因子; $a_4(i)$ 为文献[23]的收敛因子。对 4 种收敛因子的仿真结果如图 4 所示。




图 4 4 种收敛因子的变化曲线

由图 4 可以看出:在迭代初始阶段 a_1 减小速率较慢,因而 a_1 能够较长时间保持较大值,从而延长 $|A| > 1$ 的持续时间,以提高搜索效率;中期 a_1 值的衰减速率增加,使 a_1 快速减小;后期 a_1 值的衰减速率放缓,因而 a_1 能够较长时间保持较小值,延长 $|A| \leq 1$ 的持续时间,以提高搜索的精度。 a_2 表现出前期全局探索能力不强,后期局部开发能力弱。 a_3 较为注重全局探索,在迭代后期, a_3 的值是 4 种控制参数中最大的。 a_4 偏向于拓展算法局部开发能力,在迭代前中期 a_4 的值都小于其它收敛因子。

2.2.2 控制参数 C 的调整策略

GWO 算法中参数 C 的取值影响算法的寻优能力。当 $C(i) > 1$ 时,GWO 算法具有较强的局部开发能力; $C(i) \leq 1$ 时,有利于增强算法全局探索能力^[24]。为了进一步提升 GWO 算法的搜索性能,提出了一种改进策略,通过引入非线性收敛因子 $a_1(i)$ 来调节控制参数 C_1 ,其表达式为:

$$C_1(i) = 2\eta - a_1(i) \quad (17)$$

式中: $C_1(i)$ 为 C_1 在第 i 次迭代的值; $a_1(i)$ 为式(13)所得, $\eta \in [1, 1.5]$ 内的随机值。

由式(13)可知, $a_1(i)$ 的值随着迭代次数的增加从 2 减到 0,在搜索初期控制参数 $C_1(i)$ 的值小于 1 的概率较大,从而增强算法在初期时的全局探索能力;随着 $a_1(i)$ 值逐渐减小,在搜索后期控制参数 $C_1(i)$ 的值大于 1 的概率较大,从而增强算法在后期局部开发能力。图 5 给出本文改进的控制参数 C_1 、文献[23]改进的控制参数 C_2 和标准 GWO 算法中的控制参数 C 的分布值。由图 5 可以看出, C_2 在算法初期时便有值大于 1 的情况,C 始终是 0~2 内的随机值,而 C_1 在中期时值才逐步高于 1。因此本文改进的控制参数可以进一步完善 GWO 算法的搜索性能。




图 5 3 种控制参数的分布值

2.3 位置更新与种群淘汰策略

2.3.1 基于适应度值的比例权重

在灰狼追捕猎物的过程中,标准 GWO 算法位

置更新公式(8)表现出属于领导阶层的 α, β, δ 狼在引导生成新 ω 狼位置时权重所占比例相同,没有体现出不同领导阶层在位置更新过程中所占比例的重要性。因而本文采用基于适应度值的比例权重更新灰狼位置:

$$X(i+1) = \sum_{j=\alpha, \beta, \delta} w_j X_j(i) \quad (18)$$

式中: $w_j (j = \alpha, \beta, \delta)$ 为 α, β, δ 的权重系数。

$$w_j = \frac{\text{fit}(X_j(i))}{\text{fit}(X_\alpha(i)) + \text{fit}(X_\beta(i)) + \text{fit}(X_\delta(i))} \quad (19)$$

式中: $\text{fit}(X_j(i))$ 为第 j 只狼在第 i 代的适应度值。

2.3.2 种群淘汰机制

每次迭代后,选择适应度最差的 G 匹狼进行淘汰,并通过 Logistic-Tent 映射生成新的狼以替代被淘汰的狼。这样做能够剔除种群中适应度值较差的个体,避免算法后期解的位置趋于固定导致搜索停滞,促进种群的进化。本文中 G 取 $[n/2k, n/k]$ 区间内的随机整数, k 为种群淘汰比例因子,取值为 6。种群淘汰机制可以剔除适应度最差的狼,但是无法保证生成的新狼适应度值一定优于原来的解,因此将种群淘汰机制与贪心策略相结合,贪心策略使用适者生存的原则,使得新生成狼的适应度值必定优于原来的适应度值。贪心机制更新公式如下:

$$M_{i+1} = M'_i, \text{fit}(M'_i) < \text{fit}(M_i) \quad (20)$$

式中: $\text{fit}(M_i)$ 为原灰狼适应度值; $\text{fit}(M'_i)$ 为新生成的灰狼适应度值; M_{i+1} 为新生成的灰狼初始位置。在该更新过程中,若 $\text{fit}(M'_i) > \text{fit}(M_i)$,则再次使用 Logistic-Tent 映射生成新狼,直至 $\text{fit}(M'_i) < \text{fit}(M_i)$ 时停止,此时完成 1 匹狼的淘汰与更新,重复以上步骤,完成 G 匹狼的淘汰与更新。

2.4 LTGWO 算法步骤

Step 1 设置 LTGWO 算法基本参数,种群规模 N ,搜索维度 d ,最大迭代次数 I_{\max} 。

Step 2 基于 Logistic-Tent 复合混沌映射生成种群 $\{M_i\}$,根据精英反向学习策略生成精英反向种群 $\{X_n^*\}$ 。

Step 3 统计出 $\{M_i\}$ 与 $\{X_n^*\}$ 种群中每个个体相对的适应度值 $\text{fit}(M_i)$ 、 $\text{fit}(X_n^*)$ 并进行排名,将适应性排名在首位、第 2 位和第 3 位的灰狼个体分别标记为 α, β, δ 。

Step 4 根据式(13)更新收敛因子 $a_1(i)$,根据式(17)更新控制参数 $C_1(i)$ 。

Step 5 根据式(18)采用自适应比例系数更新狼群个体位置。

Step 6 淘汰适应度最差的 G 匹狼,并通过 Logistic-Tent 复合混沌映射与贪心策略生成 G 匹适应度优于被淘汰灰狼的新个体。


Step 7 若 $i < I_{\max}$, 则令 $i = i + 1$, 转至 Step3; 否则算法迭代结束, 输出最优位置。

3 仿真结果与分析


为了验证本文所提算法的有效性, 对其开展路径规划仿真实验。实验的仿真环境: Windows 10, 64 bit, CPU 频率为 2.5 GHz, 程序实现采用 MatlabR2014a。

3.1 LTGWO 算法改进策略有效性验证

为了验证第 2 节 LTGWO 算法改进策略的有效性, 设计对比实验。实验环境设置为: 在 20×20 栅格地图 1 中(如图 6(a), 模拟小型室内环境中稀疏分布的不规则障碍物地形)开展验证实验。选定起点(0,20)和终点(20,0), 对比多策略融合的 LTGWO 算法、单策略改进的 LTWO1(控制参数改进)、单策略改进的 LTWO2(位置更新与种群淘汰策略)、单策略改进的 LTWO3(种群初始化改进)和标准 GWO 算法在栅格地图 1 中行走的最短路径长度。每种算法都运行 30 次后取平均值, 实验结果如图 6 和表 1 所示。



(a) 地图 1 路径规划结果



(b) 最短路径长度变化曲线

图 6 有效性验证实验结果

由图 6(b)可以看出: 标准 GWO 算法存在前期全局探索能力不足, 后期开发能力弱, 易陷入局部最优; LTWO1 算法迭代到 13 代时短暂陷入停滞, 接

着很快跳出局部最优状态, 在 39 代时收敛, 收敛时的最短路径长度较 GWO 算法小, 说明 LTWO1 算法对控制参数的改进策略具有平衡算法全局探索与局部开发的能力, 使其不易陷入搜索停滞, 且能极大提高收敛精度, 但因其未改进种群初始化, 导致初始搜索路径较长; LTWO2 算法使用位置更新与种群淘汰策略, 相比标准 GWO 算法收敛时最短路径长度减少 4.5%, 提高了收敛精度; LTWO3 算法使用种群初始化策略, 相较于标准 GWO 算法, 其初始路径搜索结果缩短了 24.1%, 使 LTWO3 算法能较快收敛, 且收敛精度相比于 GWO 算法有所提高, 但 LTWO3 算法容易陷入局部最优, 导致搜索停滞; LTGWO 算法融合各个改进策略, 其初始搜索路径长度短、收敛速度快、收敛时最短路径长度最短, 有效改善标准 GWO 算法存在的不足, 提升了算法的整体收敛性与收敛速度。

表 1 地图 1 中各算法性能对比

算法	最短路径长度	平均路径长度	标准差
GWO	38.87	40.16	1.22
LTWO1	33.21	33.62	0.17
LTWO2	37.11	38.42	0.33
LTWO3	34.04	34.53	0.28
LTGWO	32.63	32.84	0.13

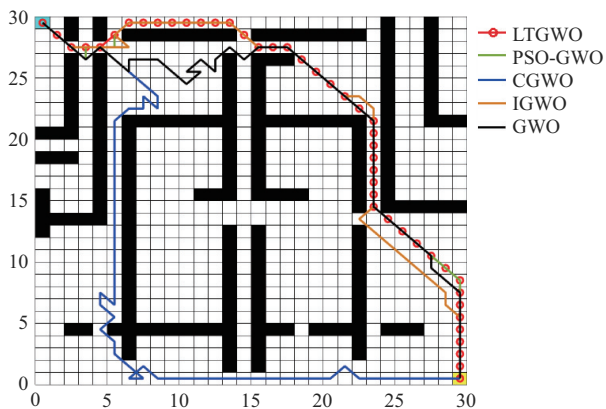
(注: 加粗字体为最优值)

由表 1 可以看出, 多策略融合改进的 LTGWO 算法的最短路径长度、平均路径长度是 5 种算法中最短的且结果最稳定, 其他逐一改进后的 LTWO1、LTWO2、LTWO3 算法比标准 GWO 算法在平均路径长度和最短路径长度方面都有所减少。


3.2 不同策略改进 GWO 算法的路径规划综合寻优能力实验

为验证 LTGWO 算法在室内不同栅格地图下的路径寻优能力, 进行 2 组不同栅格地图实验。实验环境设置为: 在地图 2(如图 7(a), 模拟中型室内环境中规则分布的障碍物地形)和地图 3(如图 8(a), 模拟大型室内环境中密集且不规则障碍物分布地形)中开展实验。分别在地图 2 和地图 3 选定起点(0,30)、(0,50), 终点(30,0)、(50,0)。实验中将 LTGWO 算法与标准 GWO 算法及近年 3 种具有代表性的改进灰狼算法进行比较, 这 3 种对比算法分别是 PSO-GWO 算法^[25]、CGWO 算法^[26]、IGWO 算法^[27], 它们由不同的研究团队提出, 并在种群初始化、收敛因子调整以及算法公式等方面做出了优化和改进。通过与这些算法在地图 2 和地图 3 中行走的最短路径长度的对比, 可以更加全面地评估本文改进方法的有效性。每种算法都运行 30 次后取平均值, 路径规划综合寻优能力实验结果分别如图

7、图 8 和表 2、表 3 所示。




(a)地图 2 路径规划结果




(b)最短路径长度变化曲线

图 7 地图 2 中 5 种算法对比结果



(a)地图 3 路径规划结果



(b)最短路径长度变化曲线

图 8 地图 3 中 5 种算法对比结果

从图 7(a)、图 8(a)可以看出,LTGWO 算法相较

于对比算法在地图 2 和地图 3 下都展现出较强的搜索能力,它能够有效地减少机器人行驶路径长度。从图 7(b)看出,LTGWO 算法的初始最短路径长度相较于 PSO-GWO 算法、CGWO 算法、GWO 算法都要短,但高于 IGWO 算法,而 IGWO 算法收敛时最短路径较大,易便陷入局部最优,反观 LTGWO 算法,其经过多次迭代,不断搜寻全局最优,最终在 50 代左右趋于稳定,收敛时最短路径长度是 5 个算法中最短的。CGWO 算法在这个地形图中全局探索效果不佳导致过早收敛,收敛时最短路径长度是 5 个算法中最长的。从图 8(b)看出,在地图 3 中,LTGWO 算法初始最短路径长度最短,虽然迭代速度不如对比算法,但 LTGWO 算法收敛时最短路径长度同样是 5 个算法中最短的。

表 2 地图 2 中 5 种算法性能对比

算法	最短路径长度	平均路径长度	标准差
GWO	58.77	61.79	4.10
PSO-GWO	53.46	54.26	3.86
CGWO	68.28	69.32	2.16
IGWO	54.87	55.17	1.70
LTGWO	51.46	54.58	1.03

(注:加粗字体为最优值)

表 3 地图 3 中 5 种算法性能对比

算法	最短路径长度	平均路径长度	标准差
GWO	78.47	79.38	0.74
PSO-GWO	76.23	76.89	0.80
CGWO	77.64	78.34	0.88
IGWO	76.81	77.85	1.37
LTGWO	74.81	75.23	0.29

(注:加粗字体为最优值)

由表 2 和表 3 可知 LTGWO 算法寻得的最短路径值分别为 51.46 和 74.81,相比 GWO 算法、PSO-GWO 算法、CGWO 算法、IGWO 算法,最优路径分别缩短了 14.2%、3.8%、32.6%、6.6% 和 4.8%、1.8%、3.7%、2.6%;在平均路径长度和标准差方面 LTGWO 算法都优于对比算法,体现出较强的鲁棒性。

综合实验结果来看,LTGWO 算法在收敛和寻优性能方面都优于 PSO-GWO 算法、CGWO 算法、IGWO 算法和 GWO 算法,能够在不同复杂环境中表现出更好的鲁棒性和适用性,而且在环境地图规模增大的情况下,依旧能展现较强的寻优能力。因此,LTGWO 算法能有效地弥补标准 GWO 算法的不足,更好地适应移动机器人路径规划需求。

3.3 不同算法路径规划综合寻优能力实验

为进一步验证 LTGWO 算法的有效性,在地图 2 和地图 3 上做路径寻优能力实验,并与 A* 算

法(A-Star algorithm, A^{*})、遗传算法(genetic algorithm, GA)、蚁群算法(ant colony optimization, ACO)进对比。实验结果如图 9、图 10、和表 4、表 5 所示。




图 9 地图 2 中 4 种算法最短路径长度变化曲线




图 10 地图 3 中 4 种算法最短路径长度变化曲线

由图 9 可知,LTGWO 算法在迭代初期最短路径长度短于对比算法,收敛速度较快,最终收敛长度是 4 个算法中最短的,GA 算法在该地图中容易陷入局部最优,在第 7 次迭代后最短路径长度就保持不变。

由图 10 可知,LTGWO 算法收敛时最短路径长度短于对比算法,A^{*} 算法和 ACO 算法最终收敛值相差不大,最长的为 GA 算法。

表 4 地图 2 中 4 种算法性能对比

算法	最短路径长度	平均路径长度	标准差
A [*]	58.97	60.64	1.46
GA	61.56	63.95	2.81
ACO	54.28	56.46	1.43
LTGWO	52.28	52.96	0.67

(注:加粗字体为最优值)

表 5 地图 3 中 4 种算法性能对比

算法	最短路径长度	平均路径长度	标准差
A [*]	77.05	78.05	1.70
GA	78.47	79.22	2.58
ACO	76.81	77.36	1.07
LTGWO	74.57	74.27	0.82

(注:加粗字体为最优值)

由表 4 和表 5 可知,LTGWO 算法寻得的最短路径值分别为 52.28 和 74.57,是 4 种算法中最短的搜索路径;在平均路径长度方面,LTGWO 算法较寻优效果最差的 GA 算法在地图 2 和地图 3 上路径分别缩短 17.1% 和 6.3%,较寻优效果排名第 2 的 ACO 算法在地图 2 和地图 3 上路径分别缩短 6.2% 和 4%;在标准差方面,LTGWO 算法都小于对比算法。

从实验结果可以看出,LTGWO 算法在 2 个地图中搜寻的最短路径长度都小于对比算法;LTGWO 算法在不同地图条件下均表现出稳定的寻优能力,特别是在地图 3 复杂性增加、障碍物分布更加密集、寻优难度进一步增加的情况下,没有出现明显的性能波动,说明 LTGWO 算法具有更高的可靠性和稳定性。

4 结论

为了提升灰狼算法在移动机器人全局路径规划中的寻优能力和收敛精度,本文提出一种基于多策略融合灰狼算法 LTGWO。该算法的核心思想在于引入混沌反向学习策略,这一策略显著增强了初始灰狼种群多样性和个体质量;同时,采用参数改进策略,算法的收敛速度和精度得到了有效提升;此外,本文还提出了位置更新与种群淘汰策略,这一策略进一步强化了算法的局部寻优能力。为了评估 LTGWO 算法在不同地形图上的性能,本文进行了路径规划综合寻优实验,这些实验结果显示,与对比算法相比,LTGWO 算法在路径寻优能力、鲁棒性、收敛速度以及环境适应能力等多个方面都展现出了明显的优势。因此,可以认为 LTGWO 算法是一种有效的全局路径规划算法,对于移动机器人的路径规划问题具有应用价值。

参考文献

[1] PATLE B K, BABU L G, PANDEY A, et al. A Review: On Path Planning Strategies for Navigation of Mobile Robot [J]. Defence Technology, 2019, 15 (4): 582-606.

[2] SÁNCHEZ-IBÁÑEZ J R, PÉREZ-DEL-PULGAR C J, GARCÍA-CEREZO A. Path Planning for Autonomous Mobile Robots: A Review [J]. Sensors, 2021, 21(23): 7898.

[3] 陈海洋,王露楠. 基于双向同时无碰撞检测目标偏置 RRT 算法的路径规划方法[J]. 空军工程大学学报(自然科学版),2022,23(3):60-67.

[4] 陈海洋,尚珊珊,任智芳,等. 基于改进蚁狮优化的贝叶斯网络结构学习算法[J]. 空军工程大学学报,

- 2023, 24(2):104-111.
- [5] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey Wolf Optimizer [J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [6] DEHGHANI M, TROJOVSKÝ P. Osprey Optimization Algorithm: A New Bio-Inspired Metaheuristic Algorithm for Solving Engineering Optimization Problems [J]. *Frontiers in Mechanical Engineering*, 2023, 8: 1126450.
- [7] TROJOVSKÁ E, DEHGHANI M, TROJOVSKÝ P. Zebra Optimization Algorithm: A New Bio-Inspired Optimization Algorithm for Solving Optimization Algorithm [J]. *IEEE Access*, 2022, 10: 49445-49473.
- [8] SAHU V S D M, SAMAL P, PANIGRAHI C K. Tyrannosaurus Optimization Algorithm: A New Nature-Inspired Meta-Heuristic Algorithm for Solving Optimal Control Problems [J]. *E-Prime-Advances in Electrical Engineering, Electronics and Energy*, 2023, 5: 100243.
- [9] BAGHERI A, ZANDIEH M, MAHDAVI I, et al. An Artificial Immune Algorithm for the Flexible Job-Shop Scheduling Problem [J]. *Future Generation Computer Systems*, 2010, 26(4): 533-541.
- [10] 李云淩, 咸日常, 张海强, 等. 基于改进灰狼算法与最小二乘支持向量机耦合的电力变压器故障诊断方法 [J]. *电网技术*, 2023, 47(4): 1470-1478.
- [11] PREMKUMAR M, SHANKAR N, SOWMYA R, et al. A Reliable Optimization Framework for Parameter Identification of Single-Diode Solar Photovoltaic Model Using Weighted Velocity-Guided Grey Wolf Optimization Algorithm and Lambert-W Function [J]. *IET Renewable Power Generation*, 2023, 17(11): 2711-2732.
- [12] LI L, HE Y D, ZHANG H, et al. Enhancing IAQ, Thermal Comfort, and Energy Efficiency through an Adaptive Multi-Objective Particle Swarm Optimizer-Grey Wolf Optimization Algorithm for Smart Environmental Control [J]. *Building and Environment*, 2023, 235: 110235.
- [13] 李博, 李欣, 芮红, 等. 基于变分模态分解和灰狼优化极限学习机的隧道口边坡位移预测 [J]. *吉林大学学报(工学版)*, 2023, 53(6): 1853-1860.
- [14] ELSISI M. Improved Grey Wolf Optimizer Based on Opposition and Quasi Learning Approaches for Optimization: Case Study Autonomous Vehicle Including Vision System [J]. *Artificial Intelligence Review*, 2022, 55(7): 5597-5620.
- [15] 刘志强, 何丽, 袁亮, 等. 采用改进灰狼算法的移动机器人路径规划 [J]. *西安交通大学学报*, 2022, 56(10): 49-60.
- [16] LV J X, YAN L J, CHU S C, et al. A New Hybrid Algorithm Based on Golden Eagle Optimizer and Grey Wolf Optimizer for 3D Path Planning of Multiple UAVs in Power Inspection [J]. *Neural Computing and Applications*, 2022, 34(14): 11911-11936.
- [17] 周建新, 郑日成, 侯宏瑶. 基于维度学习狩猎搜索策略的改进灰狼算法 [J]. *仪表技术与传感器*, 2023(12): 88-93, 98.
- [18] 薛阳, 燕宇斌, 贾巍, 等. 基于改进灰狼算法优化长短期记忆网络的光伏功率预测 [J]. *太阳能学报*, 2023, 44(7): 207-213.
- [19] HE Z H, JIN G, WANG Y J. A Novel Grey Wolf Optimizer and Its Applications in 5G Frequency Selection Surface Design [J]. *Frontiers of Information Technology & Electronic Engineering*, 2022, 23(9): 1338-1353.
- [20] FARIS H, ALJARAH I, AL-BETAR M A, et al. Grey Wolf Optimizer: A Review of Recent Variants and Applications [J]. *Neural Computing and Applications*, 2018, 30(2): 413-435.
- [21] GUPTA M, GUPTA K K, KHOSRAVI M R, et al. An Intelligent Session Key-Based Hybrid Lightweight Image Encryption Algorithm Using Logistic-Tent Map and Crossover Operator for Internet of Multimedia Things [J]. *Wireless Personal Communications*, 2021, 121(3): 1857-1878.
- [22] 龙文, 伍铁斌. 协调探索和开发能力的改进灰狼优化算法 [J]. *控制与决策*, 2017, 32(10): 1749-1757.
- [23] 武泽权, 牟永敏. 一种改进的鲸鱼优化算法 [J]. *计算机应用研究*, 2020, 37(12): 3618-3621.
- [24] 龙文, 伍铁斌, 唐明珠, 等. 基于透镜成像学习策略的灰狼优化算法 [J]. *自动化学报*, 2020, 46(10): 2148-2164.
- [25] 滕志军, 吕金玲, 郭力文, 等. 一种基于 Tent 映射的混合灰狼优化的改进算法 [J]. *哈尔滨工业大学学报*, 2018, 50(11): 40-49.
- [26] 王秋萍, 王梦娜, 王晓峰. 改进收敛因子和比例权重的灰狼优化算法 [J]. *计算机工程与应用*, 2019, 55(21): 60-65, 98.
- [27] 宋玉生, 刘光宇, 朱凌, 等. 改进的灰狼优化算法在 SVM 参数优化中的应用 [J]. *传感器与微系统*, 2022, 41(9): 151-155.

(编辑:杜娟)