

DOI:10.19651/j.cnki.emt.2209900

融合禁忌搜索的SSA算法及其路径规划的应用*

欧阳城添 唐 风 朱东林

(江西理工大学信息工程学院 赣州 341000)

摘要: 针对麻雀搜索算法易陷入局部最优解、收敛精度不足等问题,提出一种融合禁忌算法思想的改进麻雀搜索算法。首先,采用拉丁超立方抽样初始化种群,保证初始空间解分布更均匀;其次,对 $R_2 < ST$ 时引入时变柯西变异算子对发现者搜索策略进行优化;最后,在麻雀搜索算法后期收敛到一定程度时引入禁忌搜索思想,能够有效地避免算法陷入局部最优解。通过测试函数与其他算法进行仿真对比,证明该改进算法在收敛精度与速度都有极大的提升,并将其应用于移动机器人路径规划问题中,实验结果证实了在路径规划领域内的可行性与有效性。

关键词: 麻雀搜索算法;拉丁超立方抽样;柯西变异算子;禁忌搜索算法;路径规划

中图分类号: TP2 **文献标识码:** A **国家标准学科分类代码:** 510.1050

SSA algorithm with tabu search and its application in path planning

Ouyang Chengtian Tang Feng Zhu Donglin

(School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: Aiming at the problem that the sparrow search algorithm is easy to fall into the local optimum and the convergence accuracy is insufficient, this paper proposes an improved sparrow search algorithm based on tabu search algorithm. Firstly, Latin hypercube sampling is used to initialize the population to ensure a more uniform distribution of initial spatial solutions; secondly, the time-varying Cauchy mutation operator is introduced to optimize the discoverer search strategy when $R_2 < ST$; finally, the tabu search idea is introduced when the sparrow search algorithm converges to a certain extent in the later stage, which can effectively avoid the algorithm falling into the local optimal solution. Through the simulation comparison of test functions and other algorithms, it is proved that the convergence accuracy and speed of the improved algorithm are greatly improved, and it is applied to the path planning of mobile robot. The experimental results verify the feasibility and effectiveness in the field of path planning.

Keywords: sparrow search algorithm; Latin hypercube sampling; Cauchy mutation operator; tabu search algorithm; path planning

0 引 言

近几年来,优化算法广泛应用于数据挖掘^[1]、机器学习^[2]、无线传感器覆盖优化^[3]等领域,也成为众多学者解决问题的一个突破口。麻雀搜索算法^[4](sparrow search algorithm, SSA)是2020年提出的一种根据麻雀群觅食的行为的群智能优化算法,对比于常见的算法,麻雀搜索算法在收敛速度和精度、稳定性等性能都要优于其他五种优化算法^[5]。即使是性能如此优秀的麻雀搜索算法,也会像大部分的群优化算法一样,在算法搜索后期,种群多样性逐渐降低,易收敛早熟和陷入局部最优解等情况。为此,许多学者也提出了一些改进策略,郎春博等^[6]提到一个良好的

初始种群可使其在收敛速度、求解精度等方面得到一定的提升,对种群进行混沌初始化来提高初始种群质量,可以很好地保持群体多样性;刘琨等^[7]通过精英反向学习策略初始化种群,以提高初始解的质量,加快全局收敛速度;周田江等^[8]在寻优阶段采用自适应因子加快收敛,再通过模拟退火过程概率性跳出局部最优;王生生等^[9]集成了鲶鱼效应和混沌理论提出了混沌鲶鱼蜂,并引入了它与跌入局部极值的蜂群之间的有效竞争协调机制,从而增进蜜蜂群体跳出局部最优解、加速收敛的能力;吕鑫等^[10]在麻雀搜索算法改进的文献中引入 Tent 混沌搜索和高斯变异,增加了种群多样性,提高了算法的搜索性能和开拓性能,避免陷入局部最优解。陈刚等^[11]率先引入小孔成像反向学习策略

收稿日期:2022-05-11

* 基金项目:国家自然科学基金(61561024)项目资助

对发现者的位置进行更新,提升了寻优位置的多样性,再融合一种新的自适应因子,用来动态控制安全阈值,平衡了算法全局搜索与局部开发的能力,提升了算法的收敛精度与速度。以上的文献策略确实能够提升算法上性能。但在提升算法全局部搜索能力、增强算法收敛速度和帮助算法逃出局部最优等方面还有待更进一步的探索。

因此,本文在种群初始化方面用拉丁超立方抽样初始化麻雀种群来代替传统随机函数初始化的策略,有利于保证种群的多样性,而在跳出局部最优解方面,在算法搜索后期设定禁忌搜索算法(tabu search, TS)启动规则,若触发启动规则,禁忌搜索算法能够帮助麻雀搜索算法跳出局部最优解,并加快收敛速度和提升收敛精度。结合麻雀算法本身存在的问题,在发现者阶段,当 $R_2 < ST$ 时,用时变柯西变异算子进行位置更新,使麻雀每一维都可变大变小,从而提升种群的多样性。而本文结合实际应用中多变的环境,建立障碍物较多与较少的栅格地图模型进行对比,证明融合 TS 的麻雀搜索算法(SSA with tabu search, TSSSA)能够成功应用于机器人路径规划领域。

1 麻雀搜索算法概述

麻雀搜索算法(sparrow search algorithm, SSA)主要模拟了麻雀群觅食的过程,与人工蜂群算法一样也是发现者-跟随者模型,同时也加入侦查预警机制。每只麻雀都有3种行为属性:1)扮演发现者的角色,搜索食物;2)扮演跟随者的角色,跟随发现者觅食;3)侦查预警,若发现危险,立马放弃食物。在SSA中,每只麻雀的位置为适应度值,具有较高的适应度值的麻雀会率先获取食物。

作为发现者,一般占种群数的10%~20%,负责为整个麻雀种群寻找食物并为所有跟随者提供觅食的区域和方向,因此发现者具有广泛的搜索能力。每次迭代中发现者的位置更新如式(1)。

$$x_{i,d}^{t-1} = \begin{cases} x_{i,d}^t \cdot \exp(\frac{-i}{\alpha \cdot iter_{max}}), & R_2 < ST \\ x_{i,d}^t + Q, & R_2 \geq ST \end{cases} \quad (1)$$

其中, $x_{i,d}^t$ 表示种群中第 t 代第 i 个个体的第 d 维位置; $iter_{max}$ 为总的迭代数; α 为 $(0, 1]$ 中服从均匀分布的随机数; Q 为服从标准正态分布的随机数; ST 为警戒阈值,取值范围为 $[0.5, 1]$; R_2 为预警值,取值范围为 $[0, 1]$ 。当 $R_2 < ST$ 时,表示种群内部没有出现天敌,发现者可以任意地搜索食物。当 $R_2 \geq ST$,表示种群内部出现天敌并发出危险信号,因此发现者需要带领其它个体逃离当前的位置。

作为跟随者,一旦察觉发现者觅食到更好的食物,立刻离开当前的位置去争夺更好的食物,其位置更新如式(2)。

$$x_{i,d}^{t-1} = \begin{cases} Q \cdot \exp(\frac{xw_{i,d}^t - x_{i,d}^t}{i^2}), & i > \frac{n}{2} \\ xb_{i,d}^t + \frac{1}{D} * \sum_{d=1}^D (rand(-1,1)) \cdot (|xb_{i,d}^t - x_{i,d}^t|), & i \leq \frac{n}{2} \end{cases} \quad (2)$$

其中, $xw_{i,d}^t$ 为当前种群最差的位置, $xb_{i,d}^t$ 为当前种群最优的位置。

在觅食中会选取10%~20%种群数的麻雀负责侦查警戒,当发现有危险出现时,他们将放弃当前的食物而飞向一个新的位置,其位置更新如式(3)。

$$x_{i,d}^{t+1} = \begin{cases} xb_{i,d}^t + \beta \cdot (x_{i,d}^t - xb_{i,d}^t), & f_i \neq f_g \\ x_{i,d}^t + K \cdot (\frac{x_{i,d}^t - xw_{i,d}^t}{|f_i - f_w| + \epsilon}), & f_i = f_g \end{cases} \quad (3)$$

其中, β 为服从标准正态分布的随机数; K 为 $[-1, 1]$ 之间的均匀随机数; f_i 、 f_g 、 f_w 分别表示当前种群的适应度值、最优适应度值、最差适应度值。

2 融合禁忌搜索的麻雀搜索算法

2.1 禁忌搜索算法

禁忌搜索算法(TS)^[12]是局部搜索算法的一种扩展,模拟人类具有记忆功能的寻优特征,用一个禁忌表记录每一次迭代后生成的局部最优值,并在下次的搜索中,利用禁忌表里的信息不再或者有选择地搜索这些点。为了达到全局最优,禁忌搜索算法还设定“特赦准则”让一些被禁忌的优良对象可以重新选择。因此,禁忌搜索算法可以像模拟退火算法一样接受劣解,具备很强的“爬山”能力,保证多样化的有效探索,从而跳出局部最优。TS的算法流程如图1所示。

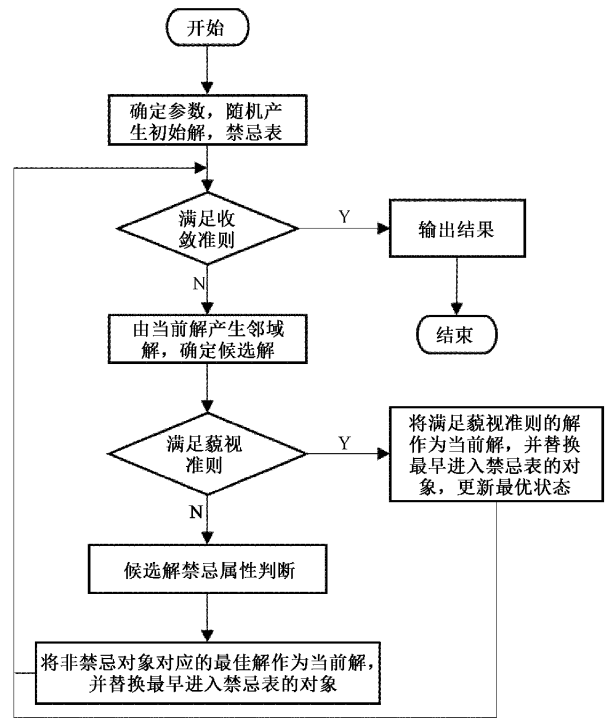


图1 TS算法流程

2.2 拉丁超立方抽样初始化种群

种群初始化是群智能优化算法不可缺少的一个环节,文献[13]研究发现群智能算法的收敛性易受初始群体分布

的影响比较大。传统麻雀搜索算法的初代种群是在可行域区间基于随机函数生成,如图 2(a)所示,可以看出随机生成的初代种群分布不均匀,从而导致算法的寻优效率大大降低。为了提升算法寻优效率以及保证样本点的随机性与均匀分布性,本文采用拉丁超立方抽样初始化种群,如图 2(b)所示,随机样本点在可行域内均匀分布,丰富了初代种群的多样性^[14]。图 2 中,种群规模 $N = 15$, 维度 $dim = 2$, 区间为 $[0, 1]$ 。




图 2 初代种群分布图

以在 n 维向量空间里抽取 m 个样本为例,拉丁超立方抽样(LHS)^[15]具体步骤如下:

- 1) 确定样本数和向量空间的维度;
- 2) 在每一维将区间等概率生成互不重叠的 m 等份;
- 3) 在每个小区间内随机生成一个随机数,即形成了 $[m, n]$ 的采样矩阵;
- 4) 在采样矩阵中的每一列随机抽取一个数,组成向量。

在 SSA 算法中用拉丁超立方抽样初始化种群,即种群数为采样矩阵中的 m , 多维决策变量对应着 n 维向量空间。利用 LHS 可产生一个 $[m, n]$ 的采样矩阵,矩阵中每一列的每一个数都是由不同小区间产生,并无序排列,形成分布范围更广泛的种群,得到多样性与收敛性好的解的概率更高。

2.3 时变柯西变异算子优化发现者位置

在 SSA 发现者阶段,式(1)中当 $R_2 < ST$ 时,麻雀个体的每一维都在变小,种群多样性也在随之减少,导致算法易

早熟收敛。因此吕鑫等^[16]中结合鸟群算法中的飞行行为,引入高斯变异算子对 SSA 中发现者在 $R_2 < ST$ 的情况下进行位置更新,即:

$$x_{i,d}^{t+1} = x_{i,d}^t + x_{i,d}^t \times randn(0,1) \quad (4)$$

其中, $randn(0,1)$ 表示均值为 0, 标准差为 1 的高斯随机分布。

高斯变异算子源于高斯分布,但与高斯分布相比,在文献[17]中表明柯西分布有着极强的相似性和具有较高的两翼概率特性,由图 3 所示,两者都主要集中在原点附近,逼近原点的速度较缓慢,它比高斯分布更容易产生远离原点的点,即产生的随机数具有更广的范围。其中 $t > 0$, 一维柯西密度(cauchy)函数为:

$$f(x) = \frac{1}{\pi} \cdot \frac{t}{t^2 + x^2}, -\infty < x < +\infty \quad (5)$$




图 3 柯西分布与高斯分布的概率密度函数曲线

若用柯西变异算子代替高斯变异算子进行发现者的位置更新,变异范围更大,有利于种群多样性增强,更能帮助算法跳出局部最优值,因此本文在发现者阶段引入柯西变异算子进行位置优化。考虑到柯西变异算子跳变的不可控性,因此在传统柯西变异算子基础上引入时变的思想,即式(6)。 t 为算法的某一代, T 为最大迭代次数, L 代表解的区间长度。

$$\lambda = L \times (1 - \sin((\frac{t}{T})^2 \cdot \frac{\pi}{2})) \quad (6)$$

黄晨晨等^[18]证实了该非线性距离控制参数(λ)比常见的非线性递减参数能更加高效地来平衡局部搜索以及全局搜索的能力。即可通过时变参数 λ , 可在算法迭代前中期,充分释放柯西变异算子的作用,保持种群的多样性;到迭代后期由于种群逐渐向最优位置靠近,进行更细致的位置更新,减少传统柯西变异算子在最优点附近之间的随机扰动,算法的收敛精度进一步得到提高,故本文中发现者的位置更新如式(7)。

$$x_{i,d}^{t+1} = \begin{cases} x_{i,d}^t \times (1 + \lambda \cdot cauchy(0,1)), & R_2 < ST \\ x_{i,d}^t + Q, & R_2 \geq ST \end{cases} \quad (7)$$

式(7)中 $cauchy(0,1)$ 表示均值为 0, 标准差为 1 的柯

西分布的柯西算子。

2.4 融合禁忌搜索的麻雀搜索算法

禁忌搜索算法虽然具备很强的局部搜索能力,但很依赖于给定的初始解,在应用中往往需要其他启发式算法给出一个较好的初始解,才能提高禁忌搜索算法的性能^[19],而麻雀搜索算法具有收敛速度快与易早熟收敛的特点。结合两种算法的优点,本文在改进SSA算法后期引入禁忌搜索思想在进行精细的局部搜索,帮助SSA算法跳出局部最优解,快速收敛到全局最优。为了减轻频繁调用TS算法造成繁重的工作量,设定一个禁忌搜索的触发规则:在算法迭代后期 $t > Q$ 时,若在连续几代内最优位置的适应度值的相对变化率小于阈值 α (很小的数),即可判定SSA算法陷入局部最优解,随即停止SSA算法运行,启动触发禁忌搜索,进行精密的寻优过程。定义式如式(8)。

$$\frac{f(t-T) - f(t)}{|f(t)|} < \alpha \quad (8)$$

其中, t 为当代迭代次数, $f(t)$ 和 $f(t-T)$ 分别表示 t 代和 $t-T$ 最优位置的适应度值。

综合以上所述改进策略,可以得到如表1所示的算法伪代码。

3 仿真实验与分析

3.1 问题描述

为了验证融合禁忌与麻雀搜索算法在实际工程应用中的可行性与有效性,结合移动机器人避障的路径规划,对机器人所在实际环境进行简化,建立二维栅格模型图,如图4所示。用该算法在栅格模型图寻找一条满足一定性能指标的从起点到终点并能避开障碍物的连续曲线^[20],从而得到最优的路径规划结果。为了方便后续研究的进行,首先给出以下条件:




图4 机器人移动方向

- 1) 设定栅格地图的起点与终点位置;
- 2) 拐点:改变机器人的移动方向,也意味着一定程度的损耗;
- 3) 机器人移动方向:向东、南、西、北、东北、东南、西南、

西北八个方向移动,如图4所示;

4) 栅格大小可根据实际障碍物的具体尺寸进行设定,障碍物的尺寸不足一个栅格时,可按一个栅格大小进行计算,能够避免在实际环境中机器人与障碍物发生碰撞。

表1 改进算法的伪代码

<i>Input</i> : $T, N, PN, SD, R_2, Q, \alpha$
<i>Output</i> : X_{best}, f_g
<i>Begin</i>
$t = 1;$
引入LHS初始化种群;
<i>While</i> ($t < T$)
根据适应度值找到当前麻雀种群的最优及最差位置。
$R2 = rand(1);$
<i>For</i> $i = 1:PN$
根据式(7)更新发现者的位置;
<i>End for</i>
<i>For</i> $i = (PN + 1):N$
根据式(2)更新追随者的位置;
<i>End for</i>
<i>For</i> $l = 1:SD$
根据式(3)更新意识到危险的麻雀个体位置;
<i>End for</i>
得到新的最优个体的位置并记录。
若新个体的位置优于之前的个体位置,则更新最优位置并记录。
<i>If</i> $t > Q$
根据式(8)是否满足禁忌搜索触发准则;
若满足,生成的个体位置优于之前的最优位置,则更新最优位置;
<i>End if</i>
$t = t + 1$
<i>End while</i>
<i>Return</i> : X_{best}, f_g
<i>end</i>

3.2 建立模型

由于在工程应用中,环境是多变的。因此,本文在仿真实验中设置两种规格(12×12、15×15)二维栅格地图模型,再在这两种规格上设立复杂(障碍物较多)与简单(障碍物较少)两类栅格,分别是144、255个栅格,每个栅格边长为1,黑色栅格代表不可行区域(有障碍物),白色栅格代表可行区域(无障碍物),在矩阵中分别用数字1和0表示。两种简单和复杂的栅格地图模型,如图5和6所示,左下角为机器人规划路径的起点,右上角为终点。

3.3 算法性能分析

为了测试TSSSA算法的性能,对表2列出的10个测




图 5 简单类型栅格地图




图 6 复杂类型栅格地图

试函数进行仿真实验,这些函数广泛应用于优化算法的性能检测中。其中 $F_1 \sim F_4$ 为高维单峰函数,用来测试算法的收敛精度和收敛速度; $F_5 \sim F_8$ 为高维多峰函数和 $F_9 \sim F_{10}$ 为低维多峰函数,用来测试算法跳出局部最优解的能力。

本节选取粒子群算法 (PSO)^[21]、灰狼优化算法 (GWO)^[22]、麻雀优化算法 (SSA)、混沌麻雀算法 (CSSA) 算法与 TSSSA 算法作为实验对比,实验选取 2 个评价算法的性能指标:1)平均值:多次运行实验,排除偶然因素对实验结果的影响,平均值越小,算法的结果越好;2)方差:实际最优值与均值之间的方差,能够反应算法求解的稳定性,方差越小,则算法的稳定性越好^[23]。

为了减少实验结果的偶然性,实验都在 MATLAB 2018a 环境下进行仿真,算法参数方面保持一致,即实验中种群数设为 21,最大迭代数为 100,发现者和负责侦查警戒的麻雀个数取种群数的 20%,禁忌搜索启动准则中 T 设为 20 代,以及各个测试函数的维度如表 2 所示,对每个测试函数都独立运行 30 次,进一步得到其平均值和方差。

从表 3 中数据可以分析出,对于 F_1 和 F_5 ,TSSSA 找到的全局最优值与其它算法相较,都是最接近理论最优值的;对于 F_2 和 F_4 ,收敛精度上至少比其他算法提升 100 个以上

表 2 测试函数

编号	函数名	函数表达式	取值区间	全局最优解
F_1	Sphere	$f(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
F_2	Schwefel2.22	$f(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$	0
F_3	Rotated Hyper-Ellipsoid	$f(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	$[-100, 100]$	0
F_4	Schwefel2.21	$f(x) = \max\{ x_i , 1 \leq i \leq n\}$	$[-100, 100]$	0
F_5	Rastrigin	$f(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$	0
F_6	Rosenbrock	$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2) + (1 - x_i)^2]$	$[-2.048, 2.048]$	0
F_7	Griewank	$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	$[-600, 600]$	0
F_8	Ackley	$f(x) = -20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	$[-32, 32]$	0
F_9	Shubert	$f(x, y) = \{ \sum_{i=1}^5 i \cos[(i+1)x + i] \} \times \{ \sum_{i=1}^5 i \cos[(i+1)y + i] \}$	$[-10, 10]$	-186.730 9
F_{10}	Schaffer	$f(x_1, x_2) = 0.5 + \frac{(\sin\sqrt{x_1^2 + x_2^2})^2 - 0.5}{(1 + 0.001 \times (x_1^2 + x_2^2))^2}$	$[-10, 10]$	0

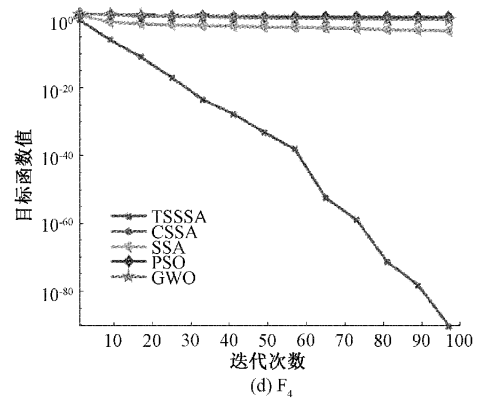



表3 算法性能对比

函数	维度	PSO		GWO		SSA		CSSA		TSSSA	
		均值	方差	均值	方差	均值	方差	均值	方差	均值	方差
F ₁	30	2.15×10 ¹	8.52×10 ²	5.91×10 ⁻²	1.25×10 ⁻³	1.30×10 ⁻³	2.00×10 ⁻⁸	6.94×10 ⁻⁶	4.98×10 ⁻¹⁰	7.82×10 ⁻²⁹⁷	0.00×10 ⁻⁰
F ₂	30	9.75×10 ⁰	1.42×10 ¹	1.84×10 ¹	3.71×10 ³	2.01×10 ³	9.72×10 ⁶	1.21×10 ³	4.23×10 ⁶	4.25×10 ⁹⁹	5.41×10 ¹⁹⁶
F ₃	30	2.04×10 ³	6.11×10 ⁵	1.12×10 ²	4.10×10 ³	1.17×10 ¹	7.53×10 ²	7.51×10 ²	1.15×10 ¹	5.47×10 ¹⁶⁵	0.00×10 ⁰
F ₄	30	8.54×10 ⁰	2.41×10 ⁰	1.58×10 ⁰	1.90×10 ⁻¹	6.59×10 ⁻⁴	8.79×10 ⁻⁹	5.92×10 ⁻⁴	1.21×10 ⁻⁶	1.76×10 ⁻¹⁰²	9.24×10 ⁻²⁰³
F ₅	30	1.57×10 ²	1.34×10 ²	5.08×10 ¹	1.86×10 ²	1.14×10 ³	3.28×10 ⁵	2.62×10 ³	5.54×10 ⁵	0.00×10 ⁰	0.00×10 ⁰
F ₆	30	2.26×10 ²	7.67×10 ³	5.91×10 ¹	5.91×10 ³	3.38×10 ⁰	6.81×10 ¹	2.11×10 ⁰	3.03×10 ¹	3.45×10 ⁻³	4.44×10 ⁻⁵
F ₇	30	1.81×10 ¹	2.54×10 ¹	1.29×10 ⁻¹	7.21×10 ⁻³	6.60×10 ⁻⁷	4.26×10 ⁻¹²	3.27×10 ⁻⁷	1.07×10 ⁻¹²	0.00×10 ⁻⁰	0.00×10 ⁻⁰
F ₈	30	3.72×10 ⁰	5.73×10 ⁻¹	9.19×10 ⁻²	1.76×10 ⁻³	8.28×10 ⁻⁴	6.32×10 ⁻⁶	5.30×10 ⁻⁴	2.27×10 ⁻⁶	8.88×10 ⁻¹⁶	1.01×10 ⁻⁶²
F ₉	2	-186.715 1	7.45×10 ⁻³	-186.373 6	6.97×10 ⁻¹	-186.730 9	0.00×10 ⁻⁰	-186.730 9	0.00×10 ⁻⁰	-186.730 9	0.00×10 ⁻⁰
F ₁₀	2	5.48×10 ⁻¹³	4.15×10 ⁻²⁴	6.79×10 ⁻¹⁴	1.38×10 ⁻²⁵	0.00×10 ⁻⁰	0.00×10 ⁻⁰	0.00×10 ⁻⁰	0.00×10 ⁻⁰	0.00×10 ⁻⁰	0.00×10 ⁻⁰

的数量级,而 TSSSA 在 F₁ 和 F₃ 上的方差均为 0,并在 F₂ 和 F₄ 的方差非常接近 0,可见稳定性极强;对于 F₅~F₈, TSSSA 无论是寻优性能方面,还是收敛精度都明显好于其他 4 种算法。在 F₅ 和 F₇ 中都能找到理论最优值 0,证明 TSSSA 具有能够跳出局部最优解的能力,并且方差为 0,算法的稳定性极强;对于 F₆ 来说,TSSSA 寻优性能没有明显的优势;而在 F₈ 中 TSSSA 精度上提升了 10 个数量级以上,并且稳定性极强;F₉~F₁₀ 均为二维的复杂函数,存在着很多极值点,由于 SSA 算法本身在低维函数上具有很强的寻优能力,因此改进之后的算法也能达到很好的效果,

但优于 PSO 算法和 GWO 算法。

为了更加直观的反映出算法的收敛特性,图 7 展示了 PSO、GWO、SSA、CSSA、TSSSA 在 F₁~F₁₀ 测试函数上的收敛曲线。从图中可以看出,PSO、GWO、SSA、CSSA 在迭代后期易陷入局部最优解,反观 TSSSA 算法在迭代过程中的收敛曲线是不断下降的,有些函数上迭代到 20 代左右时就下降得很快,即收敛速度很快,并逐渐逼近全局最优值,这归功于 TSSSA 算法加入了禁忌搜索优化阶段,避免算法陷入局部最优解。上述的实验结果可知,本文提出的 TSSSA 算法的寻优能力较强,性能稳定,能够更加有效地跳出局部最优解。



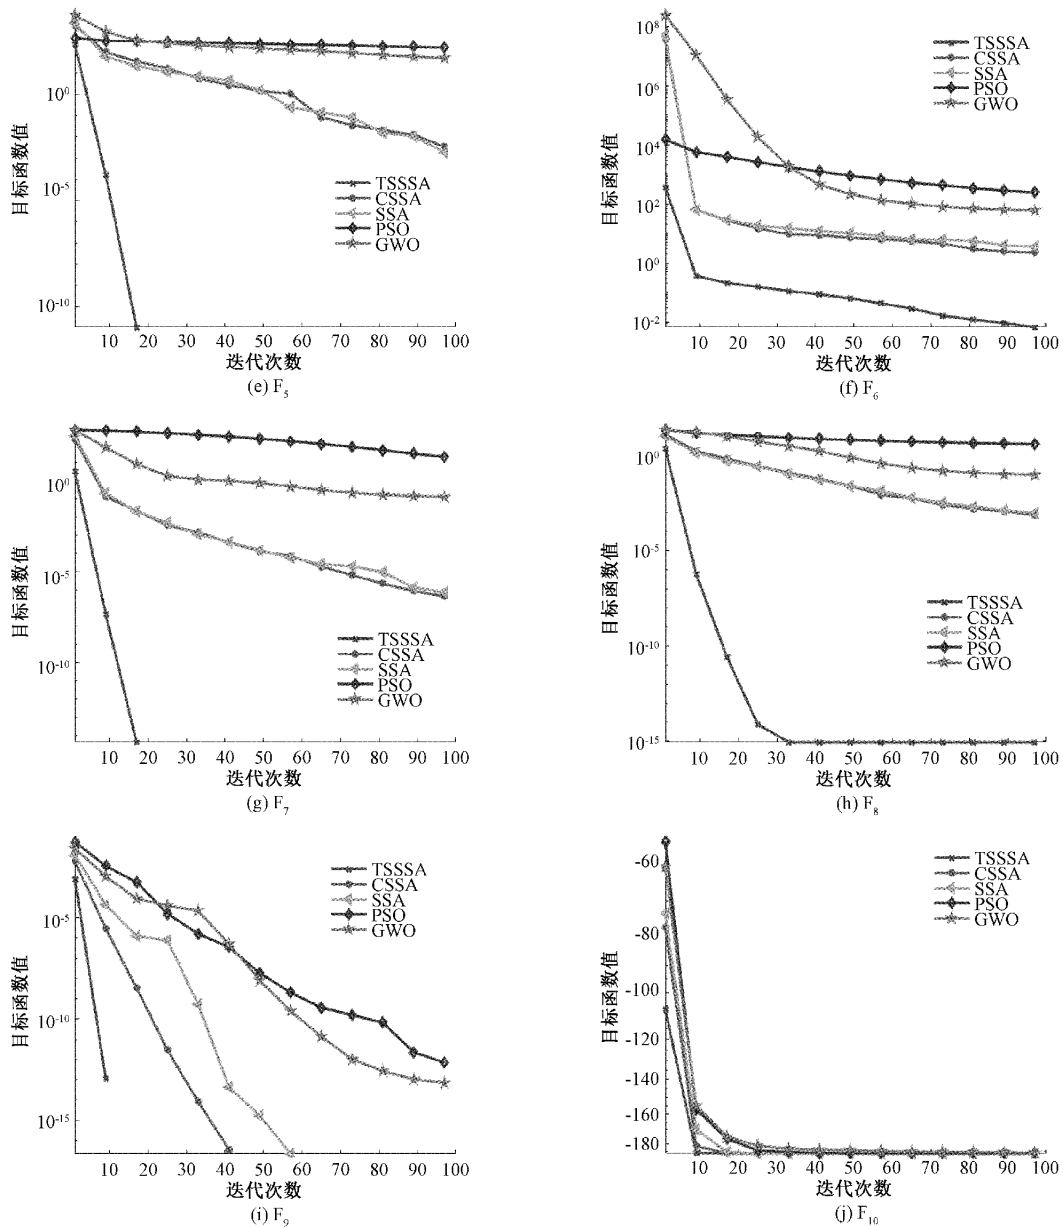


图 7 各算法在测试函数上的收敛曲线

3.4 基于 TSSSA 算法的机器人路径规划

在本文 3.2 节中建立两种不同规模栅格仿真环境中进行该融合算法在移动机器人路径规划的仿真实验,并将麻雀搜索算法与本文采用的融合算法进行性能比较。

为了排除偶然因素的影响,每次实验重复运行 30 次取平均值。主要的实验参数设置:最大迭代次数为 50,种群数为 50,其中在 30 代处,设置启动触发禁忌搜索规则,其它参数与测试函数部分一致。结果如图 8 和 9 所示。




图 8 简单环境下的路径规划




图9 复杂环境下的路径规划

由表4的实验结果可知,融合禁忌搜索的麻雀搜索算法在障碍物较多和较少的栅格地图中所获得的最短路径中转折点数量也更少,意味着机器人在避障运动过程中损耗更小。即使在非常复杂的环境下,本文采用的算法都能

有效地找出一条最短路径。实验仿真结果证明了TSSSA算法可以应用于机器人路径规划的问题,也证明了本文算法在实际路径规划应用中的可行性与有效性,也为路径规划领域提供一种新的解决方案。

表4 两种栅格地图中算法实验数据对比

评价指标	简单环境(12×12)		复杂环境(12×12)		简单环境(15×15)		复杂环境(15×15)	
	SSA	TSSSA	SSA	TSSSA	SSA	TSSSA	SSA	TSSSA
路径平均长度	15.556 3	15.556 3	18.384 8	15.556 3	19.799 0	19.799 0	28.284 3	25.455 8
转折点数量	10	6	9	7	11	8	19	10
运行时间/s	11.437 0	9.289 4	13.656 6	11.770 1	15.169 3	12.085 3	17.233 8	16.057 3

4 结 论

本文提出一种融合禁忌与改进麻雀搜索算法解决机器人路径规划问题。针对刚提出来的麻雀搜索算法易陷入局部最优解、收敛精度不足等问题,本文引入拉丁超立方抽样初始化种群,可得到在可行域区间内分布均匀的初代种群,使求得多样性与收敛性好的解的概率更高;利用时变柯西变异算子对发现者进行位置更新,既保持种群的多样性,又使算法的收敛精度得以提升;在收敛后期引入禁忌搜索思想,能够有效地避免算法陷入局部最优解,以此实现改进麻雀算法性能进一步得到提升。本文用基准测试函数证实了TSSSA算法的寻优性能方面和收敛精度都优于其他4种算法,其稳定性也更强。最后考虑到实际的工程应用,将TSSSA算法应用于移动机器人路径规划方面,结合障碍物较多与较少的实际情况,能够高效、准确地找到全局最优路径,证明了TSSSA算法在路径规划领域中的可行性与有效性。

参考文献

[1] 柏世兵. 基于神经网络和粒子群优化的数据挖掘算法的研究[J]. 激光杂志, 2017, 38(3): 88-92, DOI: 10.14016/j.cnki.jgzz.2017.03.088.

[2] 李超,熊桢,肖舒晴,等. 基于机器学习及智能算法的Au₂₀原子团簇最稳态结构的研究[J]. 数字通信世界, 2021(9): 6-7.

[3] 罗鑫. 基于改进粒子群算法的无线传感器网络覆盖漏洞修复[J]. 国外电子测量技术, 2021, 40(9): 87-92,

DOI:10.19652/j.cnki.femt.2102958.

[4] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.

[5] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.

[6] 郎春博,贾鹤鸣,邢致恺,等. 基于改进正余弦优化算法的多阈值图像分割[J]. 计算机应用研究, 2020, 37(4): 1215-1220.

[7] 刘琨,赵露露,王辉. 一种基于精英反向和纵横交叉的鲸鱼优化算法[J]. 小型微型计算机系统, 2020, 41(10): 2092-2097.

[8] 周田江,钱谦,伏云发. 融合模拟退火和自适应的天牛须搜索算法[J]. 通信技术, 2019, 52(7): 1626-1631.

[9] 王生生,杨娟娟,柴胜. 基于混沌鲶鱼效应的人工蜂群算法及应用[J]. 电子学报, 2014, 42(9): 1731-1737.

[10] 吕鑫,慕晓冬,张钧,等. 混沌麻雀搜索优化算法[J/OL]. 北京航空航天大学学报: 1-10[2020-11-23].

[11] 陈刚,林东,陈飞,等. 基于Logistic回归麻雀算法的图像分割[J/OL]. 北京航空航天大学学报: 1-14 [2022-01-05].

[12] GLOVER F. Future paths for integer programming and links to artificial intelligence[J]. Computers & Operations Research, 1986, 13(5): 533-549.

- [13] LEIGH R. Genetic algorithms in engineering systems[J]. Computing and Control Engineering, 1997, 9(2): 80.
- [14] 郑源,付晓刚,轩艳文. 基于混沌迁移的社会学习天牛群算法[J]. 上海电机学院学报, 2019, 22(3): 153-159.
- [15] MCKAY M D, BECKMAN R J, CONOVER W J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code [J]. Technometrics, 2000, 21: 239-245.
- [16] 吕鑫,慕晓冬,张钧. 基于改进麻雀搜索算法的多阈值图像分割[J/OL]. 系统工程与电子技术: 1-12 [2020-12-03].
- [17] 王战权,赵朝义,云庆夏. 进化策略中基于柯西分布的变异算子改进探讨[J]. 系统工程, 1999(4): 49-54.
- [18] 黄晨晨,魏霞,黄德启,等. 求解高维复杂函数的混合蛙跳-灰狼优化算法[J]. 控制理论与应用, 2020, 37(7): 1655-1666.
- [19] 曾令全,罗富宝,丁金嫚. 禁忌搜索-粒子群算法在无功优化中的应用[J]. 电网技术, 2011, 35(7): 129-133.
- [20] 刘宁宁,王宏伟. 基于改进灰狼优化算法的移动机器人路径规划[J]. 电测与仪表, 2020, 57(1): 76-83, 98.
- [21] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]. Mhs95 Sixth International Symposium on Micro Machine & Human Science, IEEE, 2002.
- [22] SEYEDALI M, SEYED M M, ANDREW L. Grey Wolf Optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [23] 赵玉强,钱谦,周田江,等. 天牛须搜索与遗传的混合算法[J]. 小型微型计算机系统, 2020, 41(7): 1438-1445.

作者简介

欧阳城添,博士,副教授,主要研究方向为计算机系统结构、可信计算与可靠性评估、计算智能等。

唐风,硕士研究生,主要研究方向为计算智能,机器学习等。

E-mail: tangfeng@88.com

朱东林,硕士研究生,主要研究方向为计算智能、图像分割等。