

# 禁忌搜索灰狼优化算法研究

郭玉纯, 曹小鹏, 胡元娇

(西安邮电大学 计算机学院, 陕西 西安 710121)

**摘要:**灰狼优化算法是模拟灰狼捕食行为的新型智能优化算法。原始灰狼算法由于种群迭代更新始终靠近最优解,所以存在易陷入局部最优解以及早熟收敛过快的现象。为了解决该问题,提出了一种基于禁忌搜索的灰狼优化算法,在原始灰狼优化算法中引入禁忌表的策略。禁忌表可以记录若干次历史搜索记录,下轮算法迭代可通过检索禁忌表来避免迂回搜索。当算法多次迭代且无法进一步获得更优解时,对当前最优解再进行一轮禁忌搜索,使得算法在一定次数内避免再次回到历史搜索中,进而跳出局部最优。通过对 8 个 Benchmark 基准函数的寻优测试表明,改进后的算法与原始灰狼优化算法和粒子群算法相比,其全局搜索能力获得显著提高,收敛速度加快,收敛精度更高,寻优能力更佳。

**关键词:**灰狼优化算法;禁忌搜索算法;局部搜索;局部最优

**中图分类号:**TP301.6

**文献标识码:**A

**文章编号:**1673-629X(2019)12-0055-06

**doi:**10.3969/j.issn.1673-629X.2019.12.010

## Research on Tabu Search-grey Wolf Optimization Algorithm

GUO Yu-chun, CAO Xiao-peng, HU Yuan-jiao

(School of Computer, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

**Abstract:** Grey-wolf-optimization (GWO) is a new intelligent optimization algorithm which simulates predation behavior of grey wolf. The original grey wolf algorithm is always close to the optimal solution, so it is easy to fall into the local optimal solution with too fast premature convergence. Aiming at these shortcomings, we propose an improved GWO based on the tabu search where the tabu list strategy is introduced into the basic GWO. Tabu list can record several times of historical search, and the next iteration can avoid circuitous search by searching tabu list. When the algorithm iterates for many times and cannot further obtain a better solution, another round of tabu search is conducted for the current optimal solution, so that the algorithm can avoid returning to the historical search again within a certain number of times, and then jump out of the local optimal. The optimization test of 8 Benchmark functions shows that the improved GWO has stronger global search capability, faster convergence, higher precision, and better search capability compared with basic GWO algorithm and PSO algorithm.

**Key words:** grey-wolf-optimization; tabu search; local search; local optimum

## 0 引言

2014 年澳大利亚学者 Mirjalili 模仿狼群种群围攻、捕获猎物的过程提出了灰狼优化算法 (grey-wolf-optimization, GWO)<sup>[1-3]</sup>。灰狼优化算法具有较好的计算鲁棒性和全局搜索能力,自该算法提出以来,在图像处理、图像分割<sup>[4]</sup>,无人机三维航路规划<sup>[5]</sup>,流水车间调度<sup>[6]</sup>,TSP 问题<sup>[7]</sup>,均值聚类<sup>[8]</sup>,互联网负荷频率控制<sup>[9]</sup>等方面应用广泛。

由于灰狼优化算法中灰狼种群始终向全局最优的前三个解靠近,导致其全局搜索能力较弱,对于一些复

杂优化问题,如在解决高维度、多模态复杂函数优化问题时,容易陷入局部最优和出现早熟收敛的现象。针对以上问题,张贾奎等提出了一种基于 Tent 混沌序列的灰狼算法 (TCGWO)<sup>[10]</sup>,以改善算法的寻优性能;伍铁斌提出一种基于对数函数描述收敛因子的改进 GWO 算法<sup>[11]</sup>,以避免算法出现早熟收敛;徐慧等提出了融合杜鹃搜索的灰狼优化算法<sup>[12]</sup>,在全局搜索能力方面有较为显著的提升,将其应用于特征选择中,有效提高了网络入侵检测的性能。以上文献中提出的更新策略,虽然扩大了搜索空间,但是容易跳过全局最优,

**收稿日期:**2019-01-13

**修回日期:**2019-05-15

**网络出版时间:**2019-09-24

**基金项目:**国家自然科学基金(61136002);陕西省科技计划工业公关项目(2014K06-36);陕西省教育科技计划项目(2013JK1128);西安市科技计划项目(CX12188(7))

**作者简介:**郭玉纯(1992-),男,硕士研究生,研究方向为群体智能算法优化;曹小鹏,教授,博士,CCF 会员(74354M),研究方向为软件工程。

**网络出版地址:**<http://kns.cnki.net/kcms/detail/61.1450.TP.20190924.1534.012.html>

收敛速度也会变低。

禁忌搜索通过禁忌表来记录若干次搜索历史,下轮迭代可通过检索禁忌表来避免回到历史搜索。文中通过引入禁忌搜索策略,通过对每次迭代产生的最优解 $\alpha$ 、优解 $\beta$ 、次优解 $\delta$ 个体执行禁忌搜索,从而提高算法的全局搜索能力并在算法收敛后期跳出局部最优解,且收敛速度加快。基于此,提出一种禁忌搜索灰狼优化改进算法(tabu search-grey wolf optimization, TS-GWO),并通过多组实验验证了该策略对算法寻优性能的改进。

## 1 算法描述

### 1.1 灰狼优化算法

灰狼属于犬科动物,也被认为是食物链顶端的捕食者,一般种群中包含 5~12 头狼,它们拥有十分严格的社会统治等级制度。最高领导地位的头狼被叫作 $\alpha$ 狼,负责决定捕猎的路线、休息地点、工作时间等;第二层级上的灰狼被称为 $\beta$ 狼, $\beta$ 狼是 $\alpha$ 狼的下级,它的主要工作是帮助 $\alpha$ 狼进行决策以及领导其余灰狼活动,它也是下一任 $\alpha$ 狼的最佳候选者;最低等级的灰狼就是 $\omega$ 狼, $\omega$ 狼必须遵从其他领导阶层的灰狼;剩余灰狼则为 $\delta$ 狼, $\delta$ 狼遵从 $\alpha$ 狼和 $\beta$ 狼,领导 $\omega$ 狼,这个层次的狼包含了侦察狼,哨兵,经验者,猎手以及看护者等等。

GWO 是根据灰狼的社会等级和狩猎技巧进行数学建模,将最优解记为 $\alpha$ ,将优解和次优解记为 $\beta$ , $\delta$ ;剩余的候选解则记为 $\omega$ ;  $\alpha$ 、 $\beta$ 、 $\delta$ 指导狩猎, $\omega$ 则追随三条头狼,灰狼种群捕猎的过程主要有以下几步:

(1) 包围猎物。

灰狼包围猎物的数学模型描述如下:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (1)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (2)$$

其中, $t$ 为当前迭代次数; $\vec{A}$ 和 $\vec{C}$ 为向量; $\vec{X}_p$ 为猎物的位置向量; $\vec{X}$ 为灰狼的位置向量。 $\vec{A}$ 和 $\vec{C}$ 的计算公式如下:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (4)$$

其中, $\vec{a}$ 是随迭代在 $[0,2]$ 上线性减少的向量; $\vec{r}_1$ 和 $\vec{r}_2$ 是 $[0,1]$ 上的随机向量。

(2) 攻击猎物。

$\alpha$ 狼引导 $\beta$ 狼、 $\delta$ 狼来进行猎物攻击。为了模拟灰狼捕猎,选取前三个最优解,其余灰狼根据 $\alpha$ 、 $\beta$ 、 $\delta$ 更新自己的位置,式 5~式 7 描述了这一过程。

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \end{cases} \quad (5)$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \end{cases} \quad (6)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (7)$$

### 1.2 禁忌搜索算法

禁忌搜索算法(tabu search, TS)是 1986 年由美国科罗拉多大学教授 Fred Glover 提出的一种启发式随机搜索算法<sup>[13]</sup>。禁忌搜索算法的核心就是禁忌表的建立,从过去的搜索历史中总结经验和获取知识,避免重新回到原来的搜索历史中,通过禁忌表中记录过往搜索移动,对于禁忌表中的移动,在以后的若干次迭代中是被禁止的,以免回到原来的解。这种做法,有利于在搜索陷入局部最优的时候,重新回到局部最优点,可以跳出局部最优,进行下一轮迭代搜索。其次,当候选解高于以往任何一个最优解,可特赦。禁忌搜索算法的基本流程如下:

Step1:初始化。初始解作为当前解、候选解,禁忌表为空;

Step2:在当前解的邻域选取满足不受禁忌的候选集,选取候选集中适应度值最高的一个解作为最优候选解,替换当前解;

Step3:若最优候选解的适应度值高于最优解,则替换最优解;

Step4:更新禁忌表,将最优候选解加入禁忌表,替换最早进入禁忌表的解;

Step5:判断是否满足算法停止条件,即满足收敛条件或者到达最大迭代次数,如果满足,则输出最优解,如不满足,继续返回 Step2。

禁忌搜索对初始解的要求很高,如果初始解过差,会降低收敛速度,并且容易进行无效搜索。

## 2 基于禁忌搜索的灰狼优化算法改进

GWO 算法在每一次迭代均根据灰狼首领的位置来更新所有种群个体位置,然后再计算所有种群个体的适应度值,选取最优的三个作为 $\alpha$ 、 $\beta$ 、 $\delta$ 进行位置更新以及下一次迭代,直至满足收敛条件或者达到最大迭代次数。算法每次迭代不断接近最优解,在算法初期具有较快的收敛速度,在迭代后期若灰狼首领陷入了局部最优,则其余种群个体根据精英位置更新自

己位置,均围绕在局部最优点附近,也无法脱离局部最优。因此算法在迭代后期存在全局搜索能力差的缺点,容易陷入局部最优,收敛速度变慢。而禁忌搜索算法会标记已经得到的局部最优解或求解过程,并在进一步的迭代中避开这些局部最优解或求解过程,从而获得更多的搜索区域,避免迂回搜索,进而跳出局部最优解。

为增强人工灰狼跳出局部最优解的能力,迫使狼群在不断逼近猎物的过程中,能随机地跳出局部最优,采取算法混合策略来进行算法优化,利用算法间的优势进行互补来弥补单一算法的不足,进而提升算法性能。灰狼种群根据狼群首领的位置来更新个体位置,对当前灰狼首领进行局部搜索,当其陷入局部最优时,引入禁忌表策略,对搜索历史进行记录,在后若干次的行动中禁止再回到该解位置。基于此文中提出一种基于禁忌搜索的灰狼优化改进算法,该策略主要是选取当前最优的三个解  $\alpha$ 、 $\beta$ 、 $\delta$  作为初始解进行局部的禁忌搜索,随机选取初始解邻域内的点作为候选解,进行禁忌搜索,每迭代一轮则判断是否优于当前最优解,若优于则更新最优解,并将该解加入禁忌表,否则只更新禁忌表,下一轮迭代开始前,首先判断当前候选解是否在禁忌表中,若存在,则跳过此次迭代。此时可以有效防止灰狼优化算法陷入局部最优,禁忌搜索完成后,根据选取的头狼位置更新种群个体位置,进行下一轮灰狼算法迭代。

- TS-GWO 算法的流程如下:
- Step1:种群初始化,设定最大迭代次数、维度、解空间上下限等;
- Step2:计算每个种群个体的适应度值,从中选取最优的三个解作为第一代  $\alpha, \beta, \delta$ ;
- Step3:计算参数  $a, \vec{A}, \vec{C}$ ;
- Step4:以  $\alpha, \beta, \delta$  的位置通过式 1、式 2 计算  $X_1, X_2, X_3$ ,通过式 7 计算每个灰狼的位置;
- Step5:计算每个灰狼的适应度值,选取前三作为  $\alpha, \beta, \delta$ ,以  $\alpha, \beta, \delta$  为当前解;
- Step6:在当前解的设定邻域里随机选取候选解集合;

- Step7:判断当前候选解是否存在于禁忌表中,若存在则跳过此次迭代;
- Step8:计算候选解的适应度值,若当前候选解的适应度值高于最优解,则替换最优解;
- Step9:更新禁忌表,将最优候选解加入禁忌表,替换最早进入禁忌表的解;
- Step10:判断当前解是否满足禁忌搜索收敛条件即达到最大禁忌迭代次数或达到收敛条件,若满足则跳转至 Step11,否则跳转至 Step6;
- Step11:判断是否达到灰狼优化算法最大迭代次数,若满足则跳转至 Step12,否则跳转至 Step3 进行下一次迭代;
- Step12:输出最优解。

3 实验设计与仿真分析

3.1 测试函数与对比算法

为了验证 TS-GWO 算法的性能,选取了八个测试函数进行实验仿真,并与原始 PSO<sup>[14]</sup>、GWO 算法进行比较,表 1 给出了测试函数的基本信息。文中采用平台 MATLAB 2016 ra 进行实验。为了更好地评价算法的寻优能力以及收敛精度,采用每组测试函数 50 次独立执行的结果,通过最优适应度 (best fitness, BF)、平均适应度值 (mean best fitness, MBF) 以及标准差 (standard deviation, SD)<sup>[15]</sup> 统计学指标对算法进行评价。

其中函数  $F_1 - F_5$  为单峰基准函数,在定义区间内存在全局最优值,使用智能优化算法可寻找全局最优解;函数  $F_6 - F_8$  为多峰基准函数,在定义区间内含有多个局部最优解,在算法迭代过程中,容易陷入局部最优以及产生局部震荡,可用来测试算法避免早熟收敛和脱离局部最优的能力以及对其余空间的搜索能力。

选择 TS-GWO 与 GWO、PSO 算法对上述 8 个基准测试函数进行实验,参数设置如下:种群规模  $N = 50$ ,最大迭代次数  $t = 1\ 000$ ,维度  $\text{dim} = 30$ ,禁忌搜索的禁忌迭代次数  $\text{TS-t} = 200$ ,禁忌表长度为 6-13 之间的随机数,邻域集合大小为 5。PSO 参数设置如下:  $c_1 = 2$ 、 $c_2 = 2$ 、 $w = 1.0$ 。

表 1 测试函数

函数名	函数表达式	维度	范围	全局最小值
$F_1$	$f_1(x) = \sum_{i=1}^n X_i^2$	30	$[-100, 100]$	0
$F_2$	$f_2(x) = \sum_{i=1}^n  X_i  + \prod_{i=1}^n  X_i $	30	$[-10, 10]$	0
$F_3$	$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i X_j)^2$	30	$[-100, 100]$	0
$F_4$	$f_4(x) = \max_i \{  X_i , 1 \leq i \leq n \}$	30	$[-100, 100]$	0

续表 1

函数名	函数表达式	维度	范围	全局最小值
$F_5$	$f_5(x) = \sum_{i=1}^n iX_i^4 + \text{random}[0,1)$	30	$[-1.28, 1.28]$	0
$F_6$	$f_6(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	$-418.982\ 9 \times 5$
$F_7$	$f_7(x) = \sum_{i=1}^n [x_i^2 - 10\cos 2\pi x_i + 10]$	30	$[-5.12, 5.12]$	0
$F_8$	$f_8(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos 2\pi x_i\right) + 20 + e$	30	$[-32, 32]$	0

3.2 实验结果分析

表 2 给出了八种测试函数的寻优结果的对比数据,其中 SAGWO 为文献[15]提出的具有自适应搜索策略的灰狼优化算法,表中该算法的数据来源为该文献。


由表 2 对比测试结果 BF 与 MBF 可知,TS-GWO 的寻优结果均优于原始 GWO 与 SAGWO,且 TS-GWO 与 GWO 的寻优结果远远高于 PSO,其中测试函数  $F_1 \sim F_5$  最优解 TS-GWO 比 GWO 更接近全局最小

值,收敛精度更高,表明 TS-GWO 对单峰基准函数有着更高的收敛精度;测试函数  $F_6 \sim F_8$  最优解 TS-GWO 比 GWO 更接近全局最小值,表明 TS-GWO 对多峰基准函数寻优能力更佳。对比指标 SD,TS-GWO 在稳定性上要高于 GWO、SAGWO 和 PSO。对比三项指标可得,TS-GWO 在寻优能力上比 GWO、SAGWO 和 PSO 要好,八组测试函数,  $F_1 \sim F_6$ 、 $F_8$  寻优结果 TS-GWO 均优于 GWO 与 SAGWO,函数  $F_7$  TS-GWO、SAGWO 与 GWO 均到达最优值点。


表 2 测试结果对比

函数	指标	TS-GWO	GWO	SAGWO	PSO
$F_1$	BF	4.199 0e-141	1.276 7e-72	-	1.058 8e-14
	MBF	7.890 7e-136	1.915 2e-70	4.532e-37	7.307 7e-12
	SD	4.098 8e-135	3.072 0e-70	2.541 4e-72	1.855 7e-11
$F_2$	BF	5.539 6e-72	1.194 3e-41	-	1.536 3e-07
	MBF	7.346 4e-70	1.463 1e-40	1.178 0e-22	4.820 0e+00
	SD	1.598 9e-69	1.579 627e-40	5.676 6e-44	3.373 9e+01
$F_3$	BF	1.859 6e-147	3.383 4e-25	-	1.687 2e+00
	MBF	2.391 9e-138	3.067 8e-18	-	8.455 4e+00
	SD	6.692 5e-138	1.793 6e-17	-	4.537 4e+00
$F_4$	BF	3.238 4e-82	1.886 7e-19	-	1.641 4e-01
	MBF	3.614 6e-80	8.905 5e-18	-	4.043 3e-01
	SD	7.584 9e-80	9.646 0e-18	-	1.243 9e-01
$F_5$	BF	1.216 1e-05	7.540 8e-05	-	1.933 6e-02
	MBF	7.674 1e-05	4.338 6e-04	1.152 8e-04	5.054 1e-02
	SD	5.657 7e-05	2.612 9e-04	4.005 6e-09	1.908 1e-02
$F_6$	BF	-7.850 9e+03	-4.683 4e+03	-	-2.640 9e+03
	MBF	-6.098 8e+03	-4.045 1e+03	-	-2.503 2e+03
	SD	7.604 1e+02	7.673 3e+02	-	9.508e+02
$F_7$	BF	0	7.993 6e-15	-	1.791 7e+01
	MBF	0	1.325 1e-14	0	3.856 4e+01
	SD	0	2.485 8e-15	0	1.171 4e+01
$F_8$	BF	4.440 8e-15	7.993 6e-13	-	1.789 5e-07
	MBF	7.922 5e-15	1.360 6e-14	9.776 1e-15	7.494 2e-06
	SD	4.973 7e-16	3.414 3e-13	1.629 1e-28	2.698 1e-05


为了进一步对比三种算法脱离局部最优的能力,给出了八组测试函数下的 TS-GWO,GWO,PSO 的 50 次实验执行平均最优适应度值曲线,如图 1 所示。




(a)  $F_1$  寻优迭代曲线




(b)  $F_2$  寻优迭代曲线




(c)  $F_3$  寻优迭代曲线




(d)  $F_4$  寻优迭代曲线




(e)  $F_5$  寻优迭代曲线



(f)  $F_6$  寻优迭代曲线



(g)  $F_7$  寻优迭代曲线



(h)  $F_8$  寻优迭代曲线

图 1 测试函数寻优迭代仿真



首先,通过图(a)–(h),可看出 PSO 对测试函数的寻优能力最弱,收敛精度最低,且易陷入局部最优;从图(a)–(d)可得,函数  $F_1, F_2, F_3, F_4$  中原始 GWO 已趋于平缓,即陷入了局部最优,此时 TS–GWO 仍然继续收敛,同时,两算法虽然前期收敛速度相似,但迭代多次以后,TS–GWO 性能与 GWO 相比,收敛速度加快,收敛精度也要高于原始 GWO;从图(g)可得,函数  $F_7$  实验结果 TS–GWO 与 GWO 相似,收敛速度以及最终收敛精度相差无几,但 TS–GWO 收敛速度更快;从图(h)可得,函数  $F_8$  前期迭代寻优性能相似,但在 250 代以后,GWO 陷入局部最优,此时 TS–GWO 经过数次迭代,跳出局部最优继续收敛;通过图(e)、图(f)对比函数  $F_5, F_6$  的迭代曲线,GWO 多次陷入局部最优,TS–GWO 均有能力在这种情况下跳出局部最优,达到了更高的收敛精度。

从以上实验结果以及寻优迭代曲线可以得到,TS–GWO 在处理单峰函数寻优以及多峰函数脱离局部最优的能力上,比 GWO 都有明显改善,同时具有优越的稳定性。

## 4 结束语

文中提出了一种基于禁忌搜索算法的灰狼优化算法,在灰狼优化算法中引入禁忌搜索策略,解决了灰狼优化算法容易陷入局部最优的缺点。实验结果表明,在测试函数陷入局部最优的情况下,TS–GWO 比原始 GWO 以及 PSO 更快地脱离局部最优解且其收敛精度更高,收敛速度更快。

### 参考文献:

- [1] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46–61.
- [2] MIRJALILI S, SAREMI S, MIRJALILI S M, et al. Multi-

objective grey wolf optimizer: a novel algorithm for multi-criterion optimization[J]. Expert Systems with Applications, 2016, 47: 106–119.

- [3] HOLLAND J. Genetic algorithms[J]. Scientific American, 1992, 267(1): 66–72.
- [4] 王 钰. 基于灰狼算法的智能图像分割研究[D]. 南京: 南京邮电大学, 2017.
- [5] 柳长安, 王晓鹏, 刘春阳, 等. 基于改进灰狼优化算法的无人机三维航迹规划[J]. 华中科技大学学报: 自然科学版, 2017, 45(10): 38–42.
- [6] 吕新桥, 廖天龙. 基于灰狼优化算法的置换流水线车间调度[J]. 武汉理工大学学报, 2015, 37(5): 111–116.
- [7] 许如琪, 曹 敏, 黄梦雪, 等. 基于改进灰狼优化算法的类 TSP 问题研究——以旅游为例[J]. 地理与地理信息科学, 2018, 34(2): 14–21.
- [8] 谢亮亮, 刘建生, 朱 凡. 基于灰狼优化的模糊 C-均值聚类算法[J]. 软件导刊, 2017, 16(4): 28–30.
- [9] 左 剑, 谢平平, 李银红, 等. 基于智能优化算法的互联网电网负荷频率控制器设计及其控制性能分析[J]. 电工技术学报, 2018, 33(3): 478–489.
- [10] 张贾奎, 崔利杰, 郭 庆, 等. 基于 Tent 混沌序列的灰狼优化算法[J]. 微电子学与计算机, 2018, 35(6): 11–16.
- [11] 伍铁斌, 桂卫华, 阳春华, 等. 用对数函数描述收敛因子的改进灰狼优化算法及其应用[J]. 中南大学学报: 自然科学版, 2018, 49(4): 857–864.
- [12] 徐 慧, 付迎春, 刘 翔, 等. 融合杜鹃搜索的灰狼优化算法在网络入侵检测特征选择中的应用[J]. 工程科学与技术, 2018, 50(5): 160–166.
- [13] GLOVER F. Tabu search—Part I[J]. ORSA Journal on Computing, 1989, 1(1): 89–98.
- [14] KENNEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of 1995 IEEE international conference on neural networks. Perth, Australia: IEEE, 2011: 1942–1948.
- [15] 魏政磊, 赵 辉, 韩邦杰, 等. 具有自适应搜索策略的灰狼优化算法[J]. 计算机科学, 2017, 44(3): 259–263.