

具有自适应边界与最优引导的莱维飞行蚁狮优化算法

王若安,周越文,韩 博,李剑峰,刘 强

(空军工程大学 航空航天工程学院,陕西 西安 710038)

摘 要: 针对蚁狮算法存在探索与开发能力不平衡的缺点,提出了具有自适应边界与最优引导的莱维飞行改进算法. 首先蚁狮调整边界范围,蚂蚁做莱维飞行,以此平衡探索与开发能力;其次较差蚁狮做高斯变异,并通过自适应最优引导方程,提高收敛速度和全局搜索能力. 6 个标准测试函数的仿真结果表明,相比其它算法,提出的改进算法提高了最优解的精度和收敛速度.

关键词: 蚁狮算法;莱维飞行;自适应;高斯变异;无线传感器网络

中图分类号: TP301

文献标识码: A

文章编号: 1000—7180(2018)09—0020—06

Levy Flight Ant Lion Optimizer with Adaptive Boundary and Optimal Guidance

WANG Ruo-an, ZHOU Yue-wen, HAN Bo, LI Jian-feng, LIU Qiang

(College of Aeronautics and Astronautics Engineering, Air Force Engineering University, Xi'an 710038, China)

Abstract: Aiming at the shortcoming that the ant-lion algorithm has unbalanced exploration and development capability, an improved levy flight algorithm with adaptive boundary and optimal guidance is proposed. First, the ant lion to adjust the scope of the border, ants do levy flight, in order to balance the exploration and development capabilities. Second, the worse Ant lion do Gaussian mutation, and through the adaptive best-guided equation, to improve the convergence speed and global search ability. The simulation results of six standard test functions show that the improved algorithm improves the accuracy and convergence speed of the optimal solution compared with other algorithms.

Key words: ant lion optimizer; levy flight; adaptive method; gaussian mutation; wireless sensor networks

1 引言

蚁狮优化算法(Ant Lion Optimizer, ALO)是继人工蜂群算法、蚁群算法、粒子群算法及遗传算法后提出的一种新型群集智能优化算法^[1]. 该算法模拟自然界中蚁狮的捕食行为,通过蚂蚁绕蚁狮随机游走实现全局搜索,通过优化蚁狮位置吸引蚂蚁进行局部开发. 因此在求解最优化问题方面表现出更加均衡的优越性能,并且该算法原理简单、参数设置较少,已应用于能量的最优潮流使用、分布式发电的优化定位、建立线性离散滤波器以及无人机航迹规划等领域. 但是,标准 ALO 算法同样存在后期收敛速度慢,易陷入局部最优以及搜索精度不高等问题,

从而影响了 ALO 算法的实际应用.

针对以上问题,目前学者们提出的优化策略主要体现在蚂蚁的游走方式、蚁狮的合理选取以及边界的调整策略. 文献[2]提出漩涡状收敛方式改善蚂蚁的随机游走,提高算法的收敛速度;文献[3]提出混沌搜索策略得到新的随机蚁狮,降低陷入局部最优的概率;文献[4]提出边界调整和越界处理方法,提高了算法的搜索效率. 上述改进方法虽然在所侧重的方面使 ALO 算法的性能得到优化,但是在算法搜索精度、收敛速度与陷入局部最优方面难免顾此失彼.

对于这一问题,本文根据 ALO 中蚂蚁与蚁狮的交互行为,提出一种具有自适应边界与最优引导

的莱维飞行蚁狮优化算法 (ABLALO). 首先, 将莱维飞行策略引入到蚂蚁的随机游走中; 其次, 在文献 [5] 提出的自适应搜索方法的启发下, 针对蚂蚁游走形式, 提出自适应游走边界与自适应最优引导方程, 兼顾算法前期的探索能力, 并提高了后期开发能力; 然后, 在文献 [6] 的基础上针对蚁狮被动更新的缺点, 提出主动高斯变异策略, 提高了算法跳出局部最优的能力和收敛速度; 最后, 通过对 6 个测试函数的仿真与标准 ALO 算法及 ABC 算法的比较, 并将改进算法用于无线传感器网络节点部署优化, 验证了本次改进算法的性能. 仿真结果表明, 本文提出的算法能够有效均衡探索与开发能力, 提高复杂高维函数的优化效率.

2 标准蚁狮优化算法

通过模拟蚁狮捕食蚂蚁的行为, 标准 ALO 算法遵循以下几点原则: (1) 每只蚂蚁都通过随机游走在选定蚁狮周围搜索; (2) 随机游走的范围边界受到蚁狮陷阱收缩的影响; (3) 蚁狮根据它们的适应性建立不同大小的坑, 更大的坑就有更多蚂蚁进入陷阱; (4) 每只蚂蚁在每次迭代中都同时受选定蚁狮和精英蚁狮的影响; (5) 如果蚂蚁比选定蚁狮的适应度更高, 意味着它被蚁狮捕获; (6) 蚁狮重新定位到被捕食的猎物, 并建立坑, 提高捕获另一猎物的几率. 具体实现过程如下:

按式(1) 随机生成 N 个蚂蚁和 M 个蚁狮在 D 维空间的初始解, 并分别保存在位置矩阵 $\mathbf{M}_{\text{Ant}}$ 和 $\mathbf{M}_{\text{Antlion}}$, 其中 L_d 和 U_d 是第 d 维搜索空间的下界和上界.

$$x_{i,d} = L_d + \text{rand}(0,1)(U_d - L_d) \quad (1)$$

计算每个蚂蚁和蚁狮的适应度值 $F_i = f(x_{i,1}, x_{i,2}, \dots, x_{i,D})$, 并分别保存在适应度矩阵 $\mathbf{M}_{\text{OA}}$ 和 $\mathbf{M}_{\text{OAL}}$, 其中 f 是目标函数. 同时记录全局最优位置作为精英蚁狮.

蚂蚁随机游走轨迹数组为 (其中 cumsum 是累加和, t_k 是迭代次数, $\text{rand} \in [0,1]$ 区间随机数):

$$X_t = [0, \dots, \text{cumsum}(2r(t_k) - 1)] \quad (2)$$

$$r(t_k) = \begin{cases} 1 & \text{if } \text{rand} > 0.5 \\ 0 & \text{if } \text{rand} \leq 0.5 \end{cases} \quad (3)$$

蚂蚁是围绕蚁狮在一定边界内随机搜索, 其位置 x_i^t 通过下式转换:

$$x_i^t = \frac{(x_i^t - a_i)(U_i^t - L_i^t)}{b_i - a_i} + L_i^t \quad (4)$$

式中, b_i, a_i 分别是数组 X_t 中最大和最小值; U_i^t, L_i^t 分

别是第 t 次迭代第 i 维空间的上边界和下边界, 其计算方程为:

$$\begin{cases} U_i^t = \text{Antlion}_i^t + U_i/I \\ L_i^t = \text{Antlion}_i^t + L_i/I \end{cases} \quad (5)$$

式(5) 中 Antlion_i^t 是所围绕的蚁狮位置, U_i, L_i 分别是求解问题空间的第 i 维上界和下界. 边界收缩比例 I 的方程如下:

$$I = 10^w \cdot \frac{t}{T} \quad (6)$$

其中 t 为当前迭代次数, T 为最大迭代次数. 当 $t > 0.1T, w = 2$; 当 $t > 0.5T, w = 3$; 当 $t > 0.75T, w = 4$; 当 $t > 0.9T, w = 5$; 当 $t > 0.95T, w = 6$.

根据精英策略, 全局最优的蚁狮将影响所有蚂蚁的随机游走. 第 t 代第 j 个蚂蚁的位置更新公式为:

$$\text{Ant}_j^t = \frac{R_A^t + R_E^t}{2} \quad (7)$$

式中, R_A^t 是蚂蚁在第 t 代蚁狮种群中根据适应度大小轮盘赌选定一个蚁狮, 并在其周围根据式(4) 进行随机游走后的位置. R_E^t 是该蚂蚁在第 t 代精英蚁狮周围根据式(4) 进行随机游走后的位置.

如果更新后的蚂蚁适应度大于选定蚁狮, 则更新该蚁狮的位置到蚂蚁所在处. 表示为:

$$\text{Antlion}_i^t = \text{Ant}_j^t \quad \text{if } f(A) > f(AL) \quad (8)$$

3 自适应边界与最优引导的莱维飞行 ALO 算法

对于一个群集智能优化算法, 如何均衡算法的探索和开发能力决定了其优化性能. 标准 ALO 算法因蚂蚁游走的随机性保证其探索能力, 因蚁狮向精英蚁狮靠拢保证其开发能力. 但同时可以发现, 蚂蚁的随机游走方式并不理想, 导致其游走范围小而且分散平均. 针对这一问题, 提出了蚂蚁莱维飞行策略. 下面对这四种策略作具体说明.

3.1 蚂蚁莱维飞行策略

莱维飞行 (Levy Flight) 是一种特殊的随机游走策略, 大量研究发现许多生物群体的觅食方式都可以用莱维飞行进行有效描述. 在游走过程中, 莱维飞行伴随着频繁的短距离游走和偶尔长距离游走, 因此有效均衡了算法局部开发与全局探索能力^[7].

莱维飞行的随机步长服从莱维分布, 其简化形式为:

$$L(s) \sim |s|^{-1-\beta} \quad 0 < \beta < 2 \quad (9)$$

式中, s 是随机步长. 由于莱维飞行非常复杂, 本文采

用 Mantegna 提出的算法计算,其方程如下:

$$s = \frac{\mu}{|\nu|^{\frac{1}{\beta}}} \quad (10)$$

式中, μ, ν 服从正态分布:

$$\begin{cases} \mu \sim N(0, \sigma_\mu^2) \\ \nu \sim N(0, \sigma_\nu^2) \end{cases} \quad (11)$$

$$\begin{cases} \sigma_\mu = \left[\frac{\Gamma(1+\beta) \times \sin \frac{\pi\beta}{2}}{\Gamma(\frac{1+\beta}{2}) \times \beta \times 2^{(\beta-1)/2}} \right]^{\frac{1}{\beta}} \\ \sigma_\nu = 1 \end{cases} \quad (12)$$

式中, Γ 为积分运算; β 通常取值为 1.5, 则 $\sigma_\mu = 0.6966$, 随机步长 S 的计算变得更加简便.

为了对比随机游走和莱维飞行的性能,在 Matlab 中分别用这两种方式进行 500 次随机行走,仿真结果如图 1 所示.从图中可以看出,莱维飞行具有更大的探索范围和更强的开发能力,而随机游走探索范围小并且分散平均.因此,将莱维飞行引入蚂蚁游走规则中,能有效提高蚂蚁种群的多样性和寻优能力.




图 1 随机游走和莱维飞行仿真图

3.2 蚂蚁自适应游走边界策略

由式(6)可知,蚂蚁游走的边界随迭代次数增加而缩小,但同一次迭代中,所有蚂蚁的游走边界相同,这不能反映出所围绕的蚁狮能力大小的差别,也不利于均衡算法的探索与开发能力^[8].对此,本文提出自适应边界调整策略,其方程如下:

$$I = \mu(m) \cdot 10^w \cdot \frac{t}{T} \quad (13)$$

$$\mu(m) = 0.5 + \frac{1}{1 + \exp\left(\frac{2m - M}{M^\alpha}\right)} \quad (14)$$

式中, m 是蚁狮按适应度由小到大排列的元素下标; M 是蚁狮数量; α 调整变化速率.由式(14)可知适应度最差的蚁狮其 $m = 1, \mu(m) \approx 1.5$, 边界收缩比例 I 增大,蚂蚁游走边界减小.符合较差蚁狮应该缩小陷阱,提高局部开发能力,快速找到局部最优的原理.而适应度最好的蚁狮其 $m = M, \mu(m) \approx 0.5$, I 减小,蚂蚁游走边界增大.符合较好蚁狮应该扩大陷阱,提高全局探索能力,以此跳出局部最优的原理.

3.3 蚁狮自适应最优引导策略

标准 ALO 算法为平衡探索与开发能力,采用式(7)更新蚂蚁位置,使蚁狮向精英蚁狮靠近,该方程虽然在一定程度上提高了算法的开发能力,但并没有充分考虑 ALO 算法在迭代初期需要更强的探索能力而在迭代后期需要更强的开发能力这一问题.对此,本文在文献[9]研究人工蜂群算法时提出的自适应思想基础上,提出了自适应精英蚁狮引导方程:

$$\text{Ant}_j^t = \sigma(t)R_A^t + (1 - \sigma(t))R_E^t \quad (15)$$

$$\sigma(t) = 1 - \text{rand}^{(1-t/T)^2} \quad (16)$$

式中, $\text{Ant}_j^t, R_A^t, R_E^t$ 同式(7); $\sigma(t)$ 为自适应系数; t 为当前迭代次数; T 为最大迭代次数.由式(16)可知,在迭代初期, $\sigma(t) \approx 1$, 则式(15)以围绕选定蚁狮游走为主,能够保证前期更强的探索能力,提高算法全局搜索能力,避免陷入局部最优;随着迭代次数增加, $\sigma(t) \rightarrow 0$, 则式(15)以围绕精英蚁狮游走为主,保证算法后期对最优区域进行精细化开发,从而提高算法的收敛速度和精度.通过上述改进,蚂蚁能够自适应地选择两种不同的游走方式,有效地均衡并充分发挥了算法的探索与开发能力.

3.4 蚁狮主动高斯变异策略

由式(8)可知,只有蚂蚁游走后的适应度大于其围绕的蚁狮,该蚁狮才会更新到适应度更高的位置,否则位置不变.也就是蚁狮种群中会存在适应度较差的个体,且围绕其游走的蚂蚁没有找到更优的位置,意味着该蚁狮很有可能陷入局部最优.如果保持该蚁狮位置不变,势必会继续吸引蚂蚁开发该区域,导致一定程度上弱化种群的多样性和寻优能力.对此,在文献[10]提出变异策略能有效提高种群多样性的基础上,为了增强种群的寻优能力,本文提出了最优引导的主动高斯变异策略,其方程如下:

$$X_i^{t+1} = \frac{X_i^t + X_E^t}{2} + N(0, 1) \left(\frac{X_E^t - X_i^t}{2} \right) \quad (17)$$

式中, X_E^t 是精英蚁狮的位置; $N(0, 1)$ 是服从标准高斯分布的随机函数.由式(17)可知,变异后的蚁狮

位置以 $(X_i^l + X_E^l)/2$ 为中心,在 X_i^l 和 X_E^l 之间随机产生,达到较差蚁狮向精英蚁狮学习的目的,从而提高了算法的收敛速度和跳出局部最优的能力.

该策略对 M 个蚁狮按照适应度大小排序,从中按比例 β 选取适应度较差的 $(\beta \cdot M)$ 个蚁狮,对这部分蚁狮中位置没有被动更新的个体,根据式(17)进行主动变异.最后,比较蚁狮变异前后的适应度,选择其中最优的蚁狮位置作为下一代蚁狮.

3.5 改进 ALO 算法描述

自适应边界与最优引导的莱维飞行 ALO 算法伪代码步骤如下:

```
根据式(1)初始化  $N$  个蚂蚁和  $M$  个蚁狮在  $D$  维空间的位置
计算其适应度并保存最优蚁狮的位置
while  $t \leq T$ 
  for 每只蚂蚁
    根据轮盘赌选定一个蚁狮
    根据式(5)(13)计算游走边界
    根据式(10)(4)创建随机游走并转换
    根据式(15)更新蚂蚁的位置
  end for
  计算更新后所有蚂蚁的适应度
```

```
根据式(8)更新蚁狮的位置
更新最优蚁狮的位置
根据式(17)对较差蚁狮进行变异
 $t = t + 1$ 
end while
return 最优蚁狮的位置及其适应度
```


4 仿真实验


为了验证本文提出的 ABLALO 算法性能,选取了 6 个基准函数进行测试,并与标准 ALO 算法、ABC 算法的测试结果进行比较.实验仿真软件为 MATLAB R2016a,针对三种算法,设置种群规模 $N = 40$,迭代次数 $\text{Maxcycle} = 500$,算法精度值 $\epsilon = 1e - 15$,实验次数 $K = 50$.通过对比 50 次独立实验中的平均值、最优值、最差值以及方差等参数,评价各算法的优化性能.

表 1 给出了 6 个基准函数的表达式、维数、取值范围和理论最优值,其中 $f_1 \sim f_3$ 为单峰函数, $f_4 \sim f_6$ 为多峰函数.图 2 给出了三种算法的测试收敛过程,表 2 给出了测试结果.


表 1 基准测试函数

函数表达式		维数	取值范围	最优值
(Sphere)	$f_1(x) = \sum_{i=1}^D x_i^2$	50	$[-100, 100]$	0
(Schwefel)	$f_2(x) = \sum_{i=1}^D x_i + \prod_{i=1}^D x_i $	50	$[-10, 10]$	0
(Sodp)	$f_3(x) = \sum_{i=1}^D x_i ^{(i+1)}$	50	$[-10, 10]$	0
(Rastrigin)	$f_4(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	50	$[-5, 12, 5, 12]$	0
(Griewank)	$f_5(x) = \frac{1}{4\,000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	50	$[-600, 600]$	0
(Rosenbrock)	$f_6(x) = \sum_{i=1}^D [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	50	$[-2.048, 2.048]$	0






(d) 函数 f_4 的收敛过程



(e) 函数 f_5 的收敛过程



(f) 函数 f_6 的收敛过程

图 2 6 个基准函数的测试收敛过程

表 2 ABC、ALO、ABLALO 三种算法对 $f_1 \sim f_6$ 函数的测试结果

F	Method	Best	Worst	Mean	Std
$f_1(x)$	ABC	2.573 31e-09	1.083 66e-08	5.885 82e-09	1.542 74e-09
	ALO	1.547 01e-09	1.053 51e-08	4.689 37e-09	2.134 1e-09
	ABLALO	4.454 83e-18	3.706 32e-17	1.913 8e-17	7.402 94e-18
$f_2(x)$	ABC	6.349 77e-06	2.171 12	0.270 132	0.396 867
	ALO	4.056 2e-05	0.001 2061 6	0.000 1035 66	0.000 1799 17
	ABLALO	4.101 09e-17	8.965 11e-17	6.974 47e-17	1.409 24e-17
$f_3(x)$	ABC	3.810 84e-08	1.111 92e-06	3.002 49e-07	2.070 35e-07
	ALO	6.252 82e-09	1.463 73e-07	5.263 38e-08	3.297 73e-08
	ABLALO	8.520 37e-19	9.861 04e-18	3.515 78e-18	2.340 88e-18
$f_4(x)$	ABC	0.994 959	8.954 62	3.641 55	2.189 18
	ALO	3.521 45e-11	9.949 56	2.925 18	1.932 33
	ABLALO	0	0	0	0
$f_5(x)$	ABC	0.009 864 67	0.233 998	0.074 077 4	0.049 765
	ALO	0.007 396 04	0.199 587	0.079 156	0.044 950 6
	ABLALO	0	4.052 31e-14	1.513 6e-15	7.394 25e-15
$f_6(x)$	ABC	0.005 438 17	4.621 91	0.695 249	1.508 06
	ALO	2.481 93e-05	4.192 92	0.270 142	0.981 901
	ABLALO	0.000 275 052	0.028 935 1	0.006 133 01	0.006 099 44

从图 2 可以看出,对于函数 f_1 、 f_2 、 f_3 、 f_4 、 f_6 , ALO 算法精度高于 ABC;对于函数 f_5 ,ALO 算法精度低于 ABC.整体而言这两种算法的收敛速度及搜索精度均不高,而 ABLALO 算法在 6 个基准函数的收敛过程中具有明显优越性.其中对于函数 f_1 、 f_2 、 f_3 、 f_4 、 f_5 ,改进算法在较少迭代次数下就能收敛至理论精度值,而在函数 f_6 中,ABLALO 在迭代截止时虽然没有搜索到最优值,但相比其它算法,仍具有较高的搜索精度和收敛速度.

从表 2 可以看出,改进后的算法无论是搜索精度还是稳定性,都优于标准 ALO 和 ABC 算法,AB-

LALO 算法对于单峰和多峰函数都具有较好适应性.同时可以看出,本文算法一方面采用了莱维飞行和自适应边界策略,显著提升了算法在探索和开发方面的平衡能力;另一方面采用了自适应最优引导和主动高斯变异策略,提高了收敛速度.综合得出,本文算法在略微增加计算开销的前提下,有效克服了 ALO 算法易陷入局部最优、收敛速度慢的缺点.

5 无线传感器网络节点部署优化

5.1 WSN 覆盖模型

无线传感器网络(WSN)是一种全新的信息感

知技术,由大量静止或移动的感知节点组成^[11].为了解决 WSN 节点的部署优化问题,将本文提出的 ABLALO 算法用来指导节点移动,保证了网络覆盖率的最大化. WSN 的覆盖模型描述如下:

设 WSN 监测区域大小为 50 m×50 m,将其离散化为 51×51 个像素点,区域内分布 40 个传感器节点,每个节点的感知半径为 5 m,通信半径为 10 m. ABLALO 算法中每个蚁狮的位置表示所有传感器节点的一个覆盖位置,算法的维数为 80,其中第 2*i*−1 维表示第 *i* 个节点的横坐标,第 2*i* 维表示第 *i* 个节点的纵坐标. 则传感器节点集合 $U = \{b_1, b_2, \cdots, b_{40}\}$,其中第 *i* 个节点坐标为 $b_i(x_i, y_i)$,设像素点 *G* 的坐标为 $G(x_G, y_G)$,则该像素点到第 *i* 个传感器节点的距离为 $d(b_i, G) = \sqrt{(x_G - x_i)^2 + (y_G - y_i)^2}$. 所以像素点 *G* 被传感器节点 *i* 感知的概率为:

$$p(b_i, G) = \begin{cases} 1 & d(b_i, G) \leq 5 \\ 0 & d(b_i, G) > 5 \end{cases} \quad (18)$$

如果一个像素点被多个传感器节点共同感知,则只计算一次. 于是可得节点集合 *U* 对监测区域的覆盖率为:

$$f(U) = \frac{\sum p(U, H)}{51 \times 51} \quad (19)$$

其中 *H* 为像素点集合,式(19)就是 WSN 节点部署优化模型的目标函数.

5.2 仿真结果

图 3 和图 4 分别为标准 ALO 算法和 ABLALO 算法优化后节点覆盖分布图,为与文献[12-14]的算法进行有效对比验证,针对这两种算法,设置种群规模 *N*=40,迭代次数 Maxcycle=200,取 20 次独立实验中的最优值,各算法在相同条件下优化后的覆盖率如表 3 所示.

表 3 各算法优化效果对比

算法	覆盖率/%
文献[12]	94.1
文献[13]	94.3
文献[14]	77.2
ALO	89.269 8
ABLALO	96.385 5

从仿真结果可以得出,改进算法很好地克服了标准 ALO 易陷入局部最优的缺点. ABLALO 在较少的迭代次数下,就能获得很高的覆盖率,相比其它文献的算法优化结果均有 2% 以上的提高. 经过本文算法优化,WSN 网络节点分布均匀、冗余少,虽




图 3 ALO 优化节点分布




图 4 ABLALO 优化节点分布

然存在较小的覆盖漏洞,但在 WSN 的联通范围内是允许的,不会影响网络正常工作.

6 结束语

本文在研究标准 ALO 算法原理的基础上,为了解决收敛速度慢且易陷入局部最优等问题,提出了一种具有自适应边界与最优引导的莱维飞行 ABLALO 算法. 将莱维飞行引入蚂蚁随机游走,并根据蚁狮适应度调整游走边界,提高种群多样性的同时有效平衡了算法的探索与开发能力;将较差蚁狮进行高斯变异,并通过自适应最优引导方程,提高了搜索效率,加快收敛速度的同时避免算法陷入局部最优. 通过对 6 个基准函数寻优及与 ABC 算法比较的仿真结果可以看出,ABLALO 算法在收敛速度、

(下转第 31 页)

- [6] Popescu V, Rosen P. Forward rasterization[J]. ACM Transactions on Graphics (TOG), 2006, 25(2): 375-411.
- [7] Sun C H, Tsao Y M, Lok K H, et al. Universal Rasterizer with edge equations and tile-scan triangle traversal algorithm for graphics processing units[C]//IEEE International Conference on Multimedia and Expo. IEEE Press, 2009:1358-1361.
- [8] Akeninemoller T, Haines E, Hoffman N. Real-time rendering[J]. A. k. peters Limited, 2008, 32(2):163 - 173.
- [9] Cook R L. Stochastic sampling in computer graphics [J]. Acm Transactions on Graphics, 1986, 5(1): 51-72.
- [11] Hraa. high-resolution antialiasing through multisampling[C]//USENIX Technical Conference. 2001.
- [12] 浅谈抗锯齿技术. 中关村在线. <http://hard.zol.com.cn/labs/2002/1007/48701.shtml>

- [13] Popescu V, Rosen P. Forward rasterization[J]. ACM Transactions on Graphics (TOG), 2006, 25(2): 375-411.
- [14] Shen Y L, Seo S W, Zhang Y, et al. A Low Hardware Cost 2D Vector Graphic Rendering Algorithm for Supersampling Antialiasing[J]. Computer Engineering & Applications, 2010, 1(31):141-144.

作者简介:

刘青楠 男,(1992-),硕士研究生. 要研究方向为计算机图形学. E-mail:330743434@qq.com.

曾泽沧 男,(1967-),讲师. 研究方向电路系统设计.

杜慧敏 女,(1967-),博士,教授,硕士生导师. 研究方向集成电路设计.

(上接第 25 页)

搜索精度以及鲁棒性等方面有了较大改善. 最后将改进算法用于 WSN 网络节点的部署优化,得到了满意的优化效果. 此外,作为一种较新的算法,ALO 还有许多改进方向,哪些改进策略能以较低的复杂度显著提升算法性能,是下一步需要研究的问题.

参考文献:

- [1] Mirjalili S. The ant lion optimizer[J]. Advances in Engineering Software, 2015, 83(C):80-98.
- [2] 栗然, 张凡, 靳保源,等. 基于改进蚁狮算法的电力系统最优潮流计算[J]. 电力科学与工程, 2017, 33(9):15-22.
- [3] 赵世杰, 高雷阜, 于冬梅,等. 带混沌侦查机制的蚁狮优化算法优化 SVM 参数[J]. 计算机科学与探索, 2016, 10(5):722-731.
- [4] 李宗妮,吴伟民,林志毅. 一种采用改进蚁狮优化算法的图像增强方法[J]. 计算机应用研究,2018,34(3):1-2.
- [5] Gergel V, Grishagin V, Gergel A. Adaptive nested optimization scheme for multidimensional global search[J]. Journal of Global Optimization, 2015, 66(1):1-17.
- [6] Dai X, Yuan X, Wu L. A novel harmony search algorithm with gaussian mutation for multi-objective optimization [J]. Soft Computing, 2017, 21(6): 1549-1567.
- [7] Hakl H, Uğuz H. A novel particle swarm optimization algorithm with Levy flight[J]. Applied Soft Computing Journal, 2014, 23(5):333-345.

- [8] 吴伟民, 张晶晶, 林志毅,等. 双重反馈机制的蚁狮算法[J]. 计算机工程与应用, 2017, 53(12):31-35.
- [9] 赵辉, 李牧东, 翁兴伟. 具有自适应全局最优引导快速搜索策略的人工蜂群算法[J]. 控制与决策, 2014, 28(11):2041-2047.
- [10] 李煜, 裴宇航, 刘景森. 融合均匀变异与高斯变异的蝙蝠优化算法[J]. 控制与决策, 2017, 32(10): 1775-1781.
- [11] 丁旭, 吴晓蓓, 黄成. 基于改进粒子群算法和特征点集的无线传感器网络覆盖问题研究[J]. 电子学报, 2016, 44(4): 967-973.
- [12] 赖锦辉, 梁松. 基于改进人工萤火虫算法的无线传感器网络覆盖优化[J]. 计算机测量与控制, 2014, 22(6): 1862-1864.
- [13] 王明亮, 闵新力, 薛君志. 基于改进人工鱼群算法的 WSN 覆盖优化策略[J]. 微电子学与计算机, 2015, 33(6):78-81.
- [14] 廖灿星, 张平, 李行善,等. 基于混合人工鱼群算法的传感器网络优化[J]. 北京航空航天大学学报, 2010, 36(3): 373-377.

作者简介:

王若安 男,(1993-),硕士研究生. 研究方向为自动测试系统设计. E-mail:550861874@qq.com.

周越文 男,(1972-),硕士,教授. 研究方向为测试原理.

韩博 男,(1991-),博士研究生. 研究方向为测试软件设计.

李剑峰 男,(1993-),硕士研究生. 研究方向为故障诊断与健康管理.

刘强 男,(1993-),硕士研究生. 研究方向为故障预测.