

DOI:10.19651/j.cnki.emt.2210199

# 基于混合策略麻雀搜索算法的 WSN 覆盖优化<sup>\*</sup>

陈立万<sup>1</sup> 赵尚飞<sup>2</sup> 曾蝶<sup>2</sup> 欧俊<sup>2</sup> 崔浩<sup>2</sup>

(1. 重庆三峡学院教师教育学院 重庆 404120; 2. 重庆三峡学院电子与信息工程学院 重庆 404120)

**摘要:**为了有效提高无线传感器网络的节点覆盖率,提出了一种基于混合策略麻雀搜索算法的 WSN 优化算法。利用 Tent 混沌映射初始化麻雀种群,增加种群的多样性;再用反向学习策略生成反向解扩大搜索范围,提高算法全局的搜索能力;加入惯性因子选择对预警麻雀个体进行 Levy 策略更新,提高算法局部搜索能力;对最优麻雀位置进行随机游走扰动进一步提高局部的搜索能力。仿真结果显示,HSSSA 算法使节点分布更加均匀,覆盖率有明显提高。

**关键词:**无线传感器网络;麻雀搜索算法;优化策略;覆盖率

中图分类号: TP393 文献标识码: A 国家标准学科分类代码: 510.1050

## WSN coverage optimization based on hybrid strategy sparrow search algorithm

Chen Liwan<sup>1</sup> Zhao Shangfei<sup>2</sup> Zeng Die<sup>2</sup> Ou Jun<sup>2</sup> Cui Hao<sup>2</sup>

(1. Teacher School of Education, Chongqing Three Gorges University, Chongqing 404120, China;

2. School of Electronic and Information Engineering, Chongqing Three Gorges University, Chongqing 404120, China)

**Abstract:** In order to effectively improve the node coverage of wireless sensor networks, a network coverage optimization algorithm based on hybrid strategy sparrow search algorithm is proposed. Firstly, the Tent chaotic mapping is used to improve the initialization sparrow population and increase the diversity of the population; Reverse learning strategy is used to generate inverse solutions to expand the search range and improve the global search capability; Then the inertia factor is added to select Levy strategy and update the sparrow position to improve the local search ability of the algorithm; Finally the optimal sparrow position is perturbed by random walk strategy to further improve the local search capability. The simulation results show that HSSSA algorithm resulted in a more uniform distribution of nodes and a significant improvement in coverage rate.

**Keywords:** WSN; SSA; optimization strategies; coverage rate

## 0 引言

无线传感器网络(wireless sensor networks, WSN)由能够进行传感、处理和无线通信的传感器节点组成<sup>[1-3]</sup>。多年来无线传感器网络随着科技的发展越来越备受关注,由于 WSN 大多随机部署在偏远地区或者恶劣环境条件下,造成节点冗余,无法实现网络监测区域的充分覆盖<sup>[4]</sup>。网络区域覆盖优化一直以来都是 WSN 研究中‘热点’。

近年来,智能优化算法对于 NP-hard 难点问题的解决越来越备受关注。随着启发式群体智能优化算法在 WSN 覆盖优化方面得到了很好地应用。如 Lei 等<sup>[5]</sup>提出了将反向学习策略方法加入基本的鲸鱼算法中,其改进后的算法

收敛很好,但稳定性较差,造成节点能耗加剧;胡小平等<sup>[6]</sup>提出了几种策略改进灰狼优化算法,虽然算法性能和覆盖效果上有所提升,但与其他优化算法不具备优势; Zhou 等<sup>[7]</sup>提出蜘蛛优化算法来优化传感器节点的部署,虽然有效提高检测区域的覆盖率,但算法的覆盖性有待进一步的提升。张春雨等<sup>[8]</sup>提出了主成布谷鸟算法优化无线传感器网络优化,虽然很大程度提升了网络覆盖范围,但是监测区域存在较大的节点冗余。以上文献表明启发式改进群智能优化算法可以优化网络区域覆盖,但优化效果存在不足,可以进一步改善。

2020 年一种新型的智能优化算法麻雀搜索算法(sparrow search algorithm, SSA)被 Xue 等<sup>[9]</sup>提出。该算

收稿日期:2022-06-03

\* 基金项目:重庆市教委科学技术研究项目(KJQN202101233, KJQN202001229)、重庆市人工智能+智慧农业学科群开放基金(ZNNYKFB201901)、重庆市三峡库区地质环境监测与灾害预警重点实验室开放基金(MP2020B0202)项目资助

法主要模拟麻雀生活觅食行为和反捕食行为进行数学建模。该基本算法具备很多优点,参数少,结构简单等。该算法已被广泛应用于无人机航路规划<sup>[10]</sup>,聚合物电解质燃料电池堆辨识参数优化<sup>[11]</sup>、肿瘤诊断算法检测能力提升等许多工程领域。由于 SSA 算法存在早熟且精度不高,易陷入局部最优等缺点。考虑到混沌映射策略可以提高种群的多样性,莱维飞行策略和随机游走策略对局部搜索能力的进一步增强。结合以上分析,本文提出一种基于混合策略麻雀搜索算法(hybrid strategy sparrow search algorithm, HSSSA)来优化区域覆盖。该算法通过混沌映射和反向学习生成新的初始化种群;引入 Levy 飞行策略,避免易陷入局部极值的情况;基于游走策略对最优值扰动,提高了算法全局搜索和局部探索能力。最后,基于基准函数测试算法性能和节点的覆盖优化应用。

## 1 覆盖模型

在监测区域  $M$  内,设每个传感器节点具有相同的感知半径  $r$ ,每个传感器节点覆盖范围是以  $r$  为半径的圆形区域。将监测区域离散为  $L_1 \cdot W_1$  个待覆盖的网格,各个网格中心为覆盖目标,其集合为  $P(x, y)$ ,若第  $j$  个覆盖目标点  $P_j$  与任一传感器节点距离不大于节点监测半径,则认为位置被传感器覆盖。

网络监测区域内多个传感器节点集合为  $S = \{s_1, s_2, \dots, s_N\}$ , 第  $i$  个传感器节点  $s_i$  的位置  $(x_i, y_i)$ ,  $s_i$  与覆盖目标点距离为:

$$d(s_i, p_j) = \sqrt{(x_i - x)^2 + (y_i - y)^2} \quad (1)$$

其中,所有节点在监测区域内  $L(s_i) \in M$ 。

使用布尔感知模型,对目标点监测概率为:

$$C_{x,y} = \begin{cases} 1, & d(s_i, p_j) \leq r \\ 0, & \text{其他} \end{cases} \quad (2)$$

监测区域内目标点可以被多个传感器节点同时检测,则对目标点的联合测量概率为:

$$C_{x,y}(s_{ov}, p_j) = 1 - \prod_{s_i \in s_{ov}} [1 - C_{x,y}(s_i, p_j)] \quad (3)$$

式中:  $s_{ov}$  为整体监测传感器集合。

所有节点对待检测区域的覆盖率为:

$$C_r = \frac{\sum_{x=1}^{L_1} \sum_{y=1}^{W_1} C_{x,y}(s_{ov}, p_j)}{L_1 \cdot W_1} \quad (4)$$

因此,将式(4)作为改进麻雀搜索算法求解 WSN 覆盖优化问题的目标函数,求  $C_r$  最大覆盖率。

## 2 基于混合策略的麻雀搜索算法

### 2.1 麻雀搜索算法

麻雀搜索算法<sup>[12]</sup>由 3 种担任不同角色的麻雀组成:生产者、伴随者和侦察者。首先生产者作为向导为种群觅食提供区域和方向,其适应度值较高,更容易存活下去。其次

伴随着紧密跟随生产者觅食,以保证自己捕食率的同时继续存活下去。侦察者扮演着警戒外来危险的角色,一旦发现捕食者后立即发出报警信号,使得整个种群飞离该危险区域向更安全的区域继续觅食。

麻雀集合矩阵如下:

$$\mathbf{X} = [x_1, x_2, \dots, x_N]^T, x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}] \quad (5)$$

式中: $N$  是麻雀的规模,  $i = 1, 2, \dots, N$ ,  $d$  是变量的维数。

麻雀的适应度值矩阵表示如下:

$$\mathbf{F}_x = [f(x_1), f(x_2), \dots, f(x_N)]^T, f(x_i) = [f(x_{i,1}), f(x_{i,2}), \dots, f(x_{i,d})] \quad (6)$$

其中, $N$  是表示麻雀数量,而  $\mathbf{F}_x$  中的每个值表示个体的适应度值。

1) 生产者的位置更新公式如下:

$$X_{i,j}(t+1) = \begin{cases} X_{i,j}(t) \cdot \exp\left(\frac{-i}{\alpha \cdot T}\right), & R_2 < ST \\ X_{i,j}(t) + Q \cdot L, & R_2 \geq ST \end{cases} \quad (7)$$

其中,当前迭代次数  $t$ ,最大迭代次数  $T$ ,随机数  $\alpha$  为  $[0,1]$  之间,预警值  $R_2 \in [0,1]$ ,安全值  $ST \in [0.5,1]$ ,正态分布的随机数  $Q$ ,  $1 \times d$  的矩阵  $L$ 。

2) 伴随者的位置更新公式如下:

$$X_{i,j}(t+1) = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}(t) - X_{ij}(t)}{i^2}\right), & i > \frac{N}{2} \\ X_{bestj}(t+1) + |X_{ij}(t) - X_{bestj}(t+1)| \cdot A^+ \cdot L, & i \leq \frac{N}{2} \end{cases} \quad (8)$$

其中,  $X_{worst}(t)$  表示当前全局最差位置,  $X_{i,j}(t)$  表示生产者占据的最佳位置,  $A^+ = A^T (AA^T)^{-1}$ ,  $A$  为  $1 \times d$  矩阵,  $A^T$  为  $A$  的转置。

3) 侦察者的数量占整体比例的 10%~20%,其位置更新公式如下:

$$X_{i,j}(t+1) = \begin{cases} X_{bestj}(t) + \beta \cdot |X_{ij}(t) - X_{bestj}(t)|, & f_i > f_g \\ X_{ij}(t) + K \left( \frac{|X_{ij}(t) - X_{worstj}(t)|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (9)$$

其中,  $\epsilon$  为一个常值,最佳位置  $X_{best}(t)$ ,步长控制参数  $\beta, K \in [-1,1]$ ,  $f_i$  表示当前适应度值,  $f_g$  和  $f_w$  分别为最佳值和最差值。

### 2.2 Tent 策略增加多样性

混沌映射常作为改进智能算法的手段,有助于提高群体多样性,增强算法的探索能力。相比较 Logistic 映射,Tent 映射<sup>[13]</sup>具有结构简单,分布较为均匀,遍历性好,寻优速度快等特点。对于 SSA 算法后期在寻优过程中,存在的多样性不足,易陷入局部最优,影响算法性能,因此采用一种 Tent 映射策略来解决这种问题。

Tent 映射表达式如下:

$$X_{n+1} = \begin{cases} \frac{X_n}{\alpha}, & 0 < X_n < \alpha \\ \frac{(1-X_n)}{1-\alpha}, & \alpha < X_n \leq 1 \end{cases} \quad (10)$$

其中,  $\alpha \in (0,1)$ , 一般  $\alpha$  取 0.5。

### 2.3 反向学习策略扩大搜索范围

反向学习策略是由 Tizhoosh 提出的一种优化策略<sup>[14]</sup>, 其过程是通过计算当前解的反向解来扩大搜索范围, 以增强算法的全局搜索能力, 找出问题解决的备选解。反向学习策略会加快算法的收敛速度。

假设  $X_i(t) = [x_{i1}, x_{i2}, \dots, x_{iD}]$  ( $i = 1, 2, \dots, N$ ) 是第  $t$  次迭代的一组解, 其反向解为  $X'_i(t)$ , 其含义用数学表达式表示为  $X'_i(t) = [x'_{i1}, x'_{i2}, \dots, x'_{iD}]$ , ( $i = 1, 2, \dots, N$ )。则反向解可定义为:

$$X'_i(t) = \text{rand} \cdot (l_i + u_i) - X_i(t) \quad (11)$$

式中:  $X_i(t)$  为麻雀的初始种群,  $X'_i(t)$  为麻雀的反向解种群,  $\text{rand}$  返回为随机数  $0 \sim 1$ ,  $l_i$  与  $u_i$  分别为范围的上限和下限。

将 Tent 映射生成种群和反向学习生成的种群合并为一个新的种群, 求适应度函数排序, 取前  $N$  个最优初始解得到新的麻雀初始种群。

### 2.4 Levy 策略提高局部搜索

Levy 飞行<sup>[15]</sup>搜索策略具有短距离的探索性与偶尔的大步长游走特点。短距离的探索性可以保证麻雀个体自身范围内的仔细搜索, 而偶尔的大步游走又可以保证自身进入其他区域进行更广泛的搜索。针对 SSA 算法陷入局部最优的情况, 引入 Levy 策略既可以进行局部搜索又可以进行全局搜索。因此 Levy 的引入能增强局部搜索能力, 解决 SSA 陷入局部最优的问题。在侦察者位置更新引入 Levy 策略, 很大几率避免局部最优的情况, 其改进公式如下:

$$X_{i,j}(t+1) = \begin{cases} L(d) \cdot X_{bestj}(t) + \beta \cdot |X_{ij}(t) - X_{bestj}(t)|, & f_i > f_g \\ X_{ij}(t) + K \left( \frac{|X_{ij}(t) - X_{worstj}(t)|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (12)$$

其中,  $d$  为向量维度, Levy 飞行的搜索路径  $L(d)$  如式(13)和(14)所示。

$$L(d) = 0.01 \cdot \left( \frac{u \cdot \sigma}{|v|^{\frac{1}{\beta}}} \right), \quad t < t_{\max} \quad (13)$$

$$\sigma = \left[ \frac{\Gamma(1+\beta) \cdot \sin(\frac{\pi\beta}{2})}{\Gamma(\frac{1+\lambda}{2}) \cdot \beta \cdot 2^{(\frac{\beta-1}{2})}} \right]^{\frac{1}{\beta}} \quad (14)$$

其中,  $\Gamma$  为伽马函数, 参数  $\beta$  为  $(0, 2)$  内的常数, 一般取  $\beta = 1.5$ ,  $u$  和  $v$  为  $\text{randn}(1, d)$  正态分布的随机数。

### 2.5 随机游走策略加强局部搜索

随机游走策略<sup>[16]</sup>主要是在预警麻雀搜索后, 结合鸡群算法的随机游走策略对最优麻雀适应度值进行扰动, 进一步提高其算法局部探索能力, 在开始迭代之初, 游走边界较大, 有利于提高全局搜索性, 在迭代后期, 游走边界变小, 提高算法的最优位置局部搜索性。随机游走过程可以表示为:

$$X(t) = [0, \text{cussum}(2r(t_1) - 1), \dots, \text{cussum}(2r(t_n) - 1)] \quad (15)$$

其中,  $X(t)$  为步数集;  $\text{cussum}$  为累加和;  $t$  为最大迭代次数;

$r(t)$  为一个随机函数, 定义为:

$$r(t) = \begin{cases} 1, & \text{rand} > 0.5 \\ 0, & \text{rand} \leqslant 0.5 \end{cases} \quad (16)$$

其中, 随机数  $\text{rand}$  在  $[0, 1]$  之间。

式(16)归一化处理, 由于可行域存在边界, 不能直接更新麻雀的位置。为确保在可行域范围内随机游走, 改为式(17):

$$X_i(t) = \frac{(X_i(t) - a_i) \times (d_i(t) - c_i(t))}{(b_i - a_i)} + c_i(t) \quad (17)$$

其中,  $a_i$  为最小值;  $b_i$  为最大值;  $c_i(t)$  与  $d_i(t)$  分别为第  $t$  次迭代的最小值和最大值。

## 3 覆盖算法优化步骤

输入为 HSSSA 的种群数量  $pop$  和最大迭代次数  $Max\_Iter$ , 以及监测区域面积  $S = L_1 \cdot W_1$ , 像素点数  $m \times n$ , 传感器点数  $N$  和感知半径  $r$  等参数; 输出  $C_r$  最优适应度值, 以及节点分布位置。HSSSA 算法优化步骤如下:

步骤 1) 初始化参数, 设定搜索空间  $L_1 \cdot W_1$ , 覆盖节点个数  $N$ , 通信半径  $R$ , 感知半径  $r$ , 种群数量  $pop$ , 最大迭代次数  $Max\_iter$ , 维度  $dim$ , 上界  $ub$  与下界  $lb$  等; HSSSA 算法相关参数, 安全值  $ST$ , 预警值  $R_2$  与生产者的比例  $PD$  等, 初始适应度函数;

步骤 2) 初始化种群, 迭代次数, 初始化生产者和伴随者数量, 根据安全值  $ST$  与生产者比例  $PD$  计算生产者数量  $PDNumber$  与意识到危险的麻雀比例数量  $SDNumber$ ;

步骤 3) 根据式(10)由 Tent 混沌映射初始化种群数量  $pop$ , 使种群更具多样性, 生成初始解向量;

步骤 4) 根据式(11)利用反向学习策略求出初始解向量的反向解向量, 将初始解向量与反向解向量合并成新的种群;

步骤 5) 求解适应度函数, 将适应度函数按升序排列, 取出最优的初始解放到新的初始种群中;

步骤 6) 再次计算初始适应度值并排序, 确定全局最优适应度值  $F_{best}$  与最差适应度值  $F_{worst}$ , 得到全局最优位置  $G_{Xbest}$  与最差位置  $G_{Xworst}$ ;

步骤 7) 初始化惯性因子  $factor$ ;

步骤 8) 根据式(7)更新生产者位置;

步骤 9) 根据式(8)更新伴随着位置;

步骤 10) 根据式(9)更新侦察者位置;

步骤 11) 计算适应度值并更新麻雀位置;

步骤 12) 计算惯性权重因子  $factor = 1 - i/Max\_Iter$ ,

利用轮盘选择如果  $rand > factor$ , 根据式(12)对选择的麻雀个体进行 Levy 飞行搜索;

步骤 13)再次更新适应度值并排序, 根据式(17)利用最优位置  $G_{Xbest}$  与最差位置  $G_{Xworst}$  对麻雀进行随机游走策略, 提高其搜索能力, 再次更新全局最优位置;

步骤 14)判断是否满足停止条件, 满足则退出, 获得最优适应度值和节点分布位置, 否则, 重复执行步骤 5)~13)。

基于 HSSSA 算法的流程如图 1 所示。

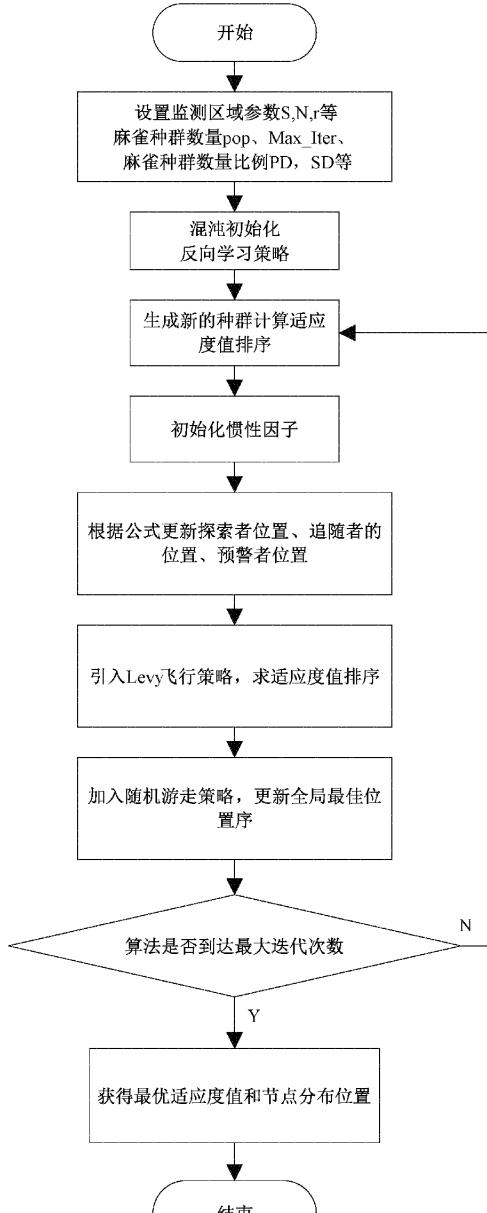


图 1 覆盖优化流程

## 4 仿真实验与分析

### 4.1 算法性能测试

为了验证 HSSSA 算法在无线传感网络上的覆盖性

能, 选取了 SSA 算法、融合莱维飞行策略的麻雀搜索算法(记为 SSAL)、融合鸡群随机游走策略的麻雀搜索算法(记为 SSARW)3 种算法进行比较, 表 1 为 4 种经典的测试函数下进行综合性比较。选取两组单峰函数 F1 和 F2, 两组多峰函数 F3 和 F4。

表 1 基准测试函数

函数	维度	搜索范围	最小值
F1 SCHWEFEL 1. 2	30	[−100 100]	0
F2 SCHWEFEL 2. 21	30	[−100 100]	0
F3 GRIEWANK	30	[−600 600]	0
F4 PENALIZED	30	[−50 50]	0

### 4.2 收敛曲线分析

为了对比算法的收敛性, 设置相同的环境变量, 将改进的 HSSSA 算法同其他 3 种算法独立运行 30 次, 求解测试函数的结果进行比较。如表 2 为算法的参数设置。表 3 为基准函数测试仿真结果, 将算法的平均值和标准差作为评价指数进行了仿真实验。

表 2 参数设置

算法	参数设置
SSA	$PD = 0.2, SD = 0.1, R_2 = 0.6$
SSAL	$PD = 0.2, SD = 0.1, R_2 = 0.6$
SSARW	$PD = 0.2, SD = 0.1, R_2 = 0.6$
HSSSA	$PD = 0.2, SD = 0.1, R_2 = 0.6, \alpha = 0.5$

表 3 测试函数结果( $dim=30$ )

函数	算法	平均值	标准差
F1	HSSSA	$2.94 \times 10^{-76}$	$3.99 \times 10^{-76}$
	SSAL	$3.50 \times 10^{-8}$	$8.95 \times 10^{-7}$
	SSARW	$5.83 \times 10^{-36}$	$1.74 \times 10^{-32}$
	SSA	$1.79 \times 10^{-7}$	$2.29 \times 10^{-7}$
F2	HSSSA	$2.07 \times 10^{-114}$	$3.59 \times 10^{-114}$
	SSAL	$9.75 \times 10^{-6}$	$1.13 \times 10^{-5}$
	SSARW	$1.69 \times 10^{-9}$	$1.12 \times 10^{-8}$
	SSA	$2.2043 \times 10^{-13}$	$2.3893 \times 10^{-13}$
F3	HSSSA	$2.84 \times 10^{-11}$	$3.29 \times 10^{-11}$
	SSAL	$3.43 \times 10^{-8}$	$5.42 \times 10^{-8}$
	SSARW	$3.68 \times 10^{-9}$	$1.35 \times 10^{-8}$
	SSA	$2.63 \times 10^{-9}$	$4.69 \times 10^{-9}$
F4	HSSSA	1.000 8	0.005 1
	SSAL	0.997 6	0.014 5
	SSARW	0.999 9	0.001 8
	SSA	0.998 8	0.014 5

由图 2(a)和(b)可以看出, HSSSA 的收敛曲线较陡,

而 SSA、SSAL 和 SSARW 算法收敛呈现平缓趋势, 表明 SSA、SSAL 和 SSARW 算法的寻优能力都不及 HSSSA 算

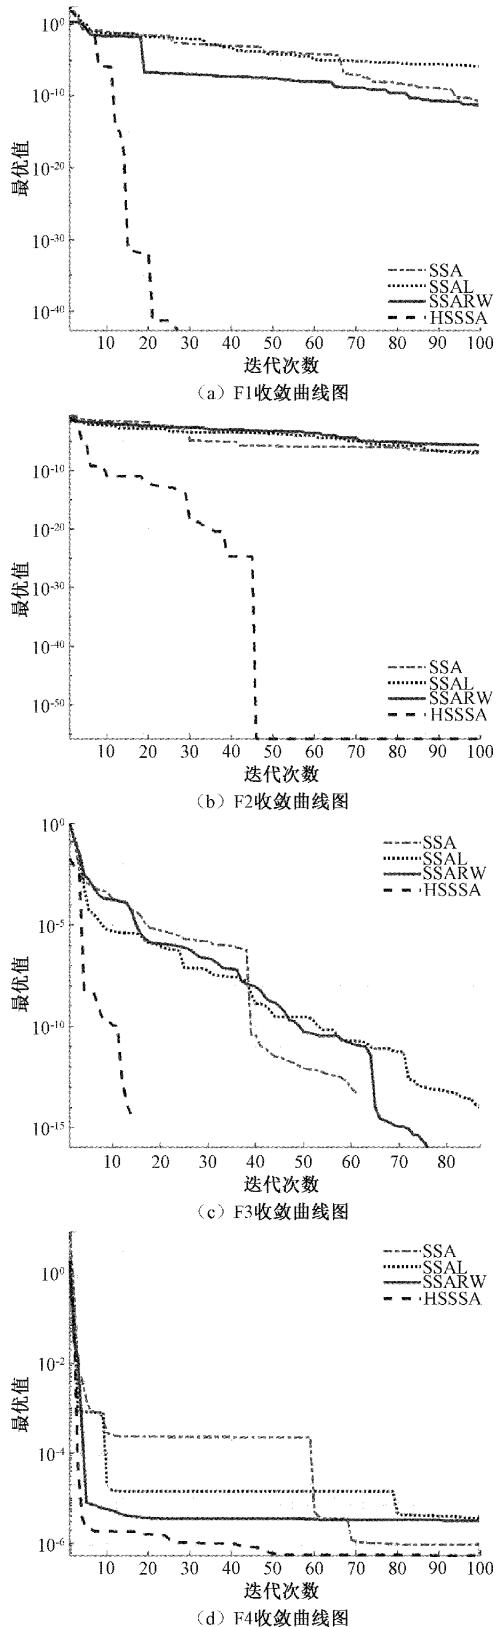


图 2 优化函数测试收敛曲线对比

法。对于单峰函数 F1 和 F2 求解, 由表 3 知, HSSSA 的平均值和标准差都小于 SSA、SSAL 和 SSARW 数十数量级, 表明 HSSSA 精度更高, 稳定性更强。从由图 2(c) 和(d)可知, 相比较 SSA、SSAL 和 SSARW, HSSSA 算法收敛速度最快, 且最先搜索到最优值, 寻优性最佳。对于多峰函数 F3 和 F4 求解, 从表 3 可以看出 HSSSA 的精度高于 SSA、SSAL 和 SSARW 2~3 个数量级, 求解精度更高, 更容易寻到最优解。

结果表明, Tent 混沌策略和反向学习策略初始化种群的多样性, 莱维飞行策略和随机游走策略加强了算法全局探索和局部搜索能力, 使得改进的麻雀搜索算法更具优势。

#### 4.3 WSN 覆盖优化应用

##### 1) 仿真设置

仿真实验验证 HSSSA 算法对 WSN 节点覆盖的优化性能, 选取 SSA 算法和 4 种不同改进策略的麻雀搜索算法做比较。分别在相应监测区域进行传感器节点覆盖优化对比, 取 30 次独立运算的平均覆盖率作为评价指标。

##### 2) 监测区域覆盖优化对比

假设在面积  $S = 100 \text{ m} \times 100 \text{ m}$  的监测区域, 像素点数  $100 \times 100$ , 节点个数  $N = 20$ , 感知半径  $r = 7.5$ , 通信半径  $R = 15$ , 在迭代次数  $Max\_Iter = 500$  时, 30 轮计算取平均覆盖率对比, 图 3 和 4 分别为算法优化后节点覆盖优化收敛曲线图和节点分布图。

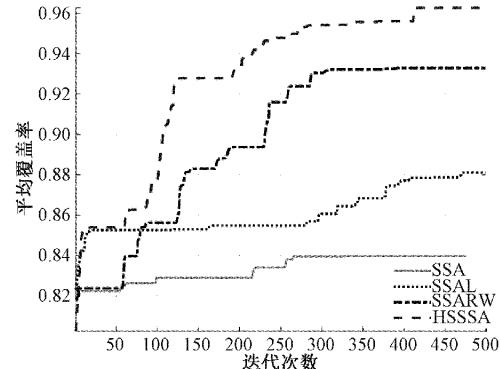
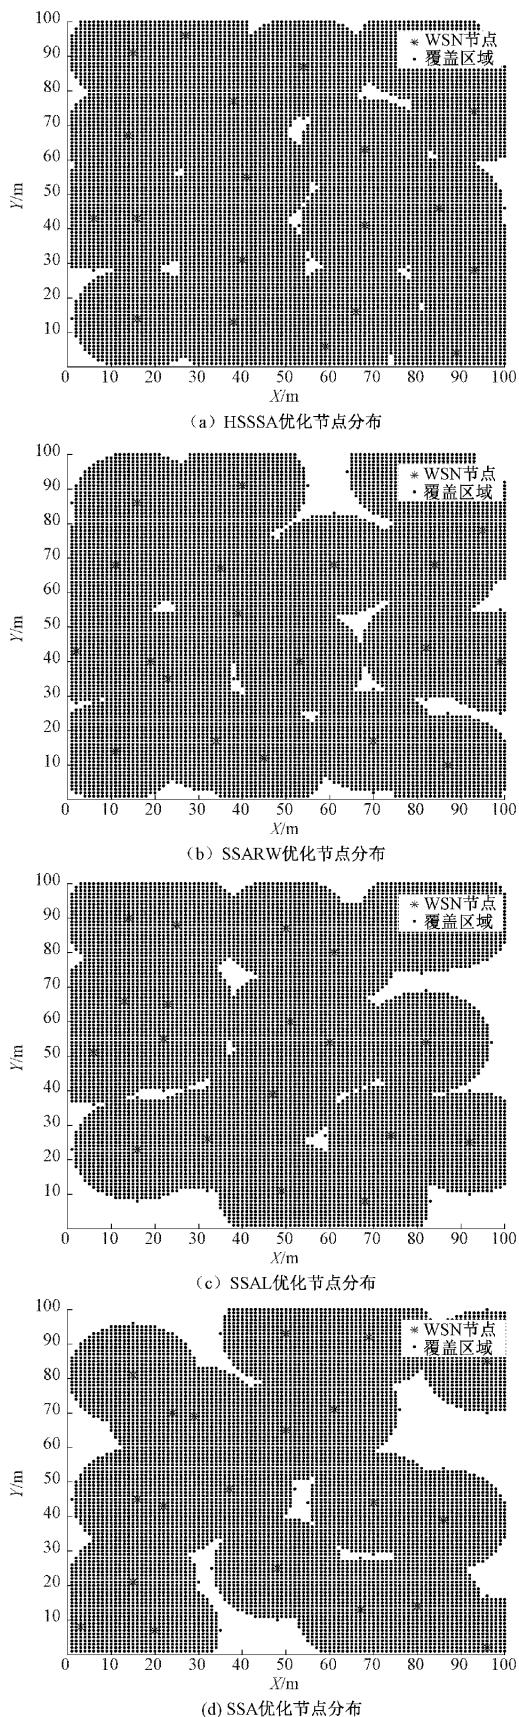


图 3 节点覆盖优化收敛曲线

由图 3 可知, 基本 SSA 算法在迭代次数 250 左右覆盖率就达到了 84% 左右, 虽然在迭代前期就取得了不错的覆盖效果, 但后期就一直未跳出局部最优。而 SSARW 算法相比于 HSSSA 算法来说, 两者覆盖率都在逐步提高, 但是 HSSSA 算法提高效果显著, 且在 200 代左右就达到了 SSARW 的最大覆盖率。SSAL 算法的迭代次数为 50 次内时取得 85% 左右的覆盖率, 之后提升效果开始下降, 不如 HSSSA 算法优化效果。

如图 4 所示是 HSSSA、SSARW、SSAL 和 SSA 算法的覆盖优化图, 观察图 4(b)~(d) 可知, HSSSA 覆盖阴影面积最大, SSARW、SSAL 和 SSA 阴影面积依次减少, 而 SSA

图 4 优化节点分布( $\text{Max\_Iter}=500$ )

算法阴影重叠明显,且空白覆盖盲区最大。相比于其他算法,HSSSA 算法覆盖效果最佳,节点分布更为均匀。

表 4 给出了 500 代内的 SSA 算法、SSAL 算法、SSARW 算法和 HSSSA 算法的平均覆盖率结果对比。由表 4 可知,在同等的仿真实验条件下,HSSSA 算法运行 30 次所得的平均覆盖率为 96.28%,相比于 SSA、SSAL 和 SSARW 算法分别提高了 12.11%、8.16% 和 2.99%。

表 4 覆盖率优化对比( $\text{Max\_Iter}=500$ )

算法	平均覆盖率(30 runs)
SSA	84.17%
SSAL	88.12%
SSARW	93.29%
HSSSA	96.28%

综上所述,HSSSA 算法具有收敛速度快,全局探索能力强等特点,将 HSSSA 应用于 WSN 覆盖优化问题上,通过与不同算法在相同的环境下测试结果对比,HSSSA 算法实现了覆盖率最大,节点分布均匀,覆盖盲区少。

## 5 结 论

本文首先分析了优化策略的原理,然后将混合策略加入到麻雀搜索算法中,分析 HSSSA 算法的原理。通过算法仿真实验,得出混合策略改进的算法在收敛性和鲁棒性上都优于其它单一策略算法的改进和标准算法。最后,将 HSSSA 算法应用无线传感器网络中,从实验结果知,HSSSA 算法的覆盖效果依次优于 SSARW、SSAL 和 SSA 三种算法。因此,提出的 HSSSA 算法能够有效提升无线传感器网络的覆盖率。另外,如何在最大覆盖率的情况下进行节点节能,以延长网络生存周期,将是基于 HSSSA 算法优化下一步需要解决的问题。

## 参 考 文 献

- [1] QIN N N, CHEN J L. An area coverage algorithm for wireless sensor networks based on differential evolution[J]. International Journal of Distributed Sensor Networks, 2018, 14(8):1-11.
- [2] ZHU L, FAN C X, WEN Z G, et al. Coverage optimization strategy for WSN based on energy-aware[J]. International Journal of Computers Communications & Control, 2016, 11(6):877-888.
- [3] XU Y, OU D, RONG Q, et al. Hybrid multi-objective evolutionary algorithms based on decomposition for wireless sensor network coverage optimization [J]. Applied Soft Computing Journal, 2018, 68:268-282.
- [4] 李文. 基于权值-阈值自优化机制的 WSN 均衡覆盖算法[J]. 电子测量技术, 2021, 44(6):130-134.

- [5] LEI W, WU W, QI J, et al. Wireless sensor network coverage optimization based on whale group algorithm[J]. Computer Science and Information Systom, 2018, 15(3):569-583.
- [6] 胡小平,曹敬.改进灰狼优化算法在WSN节点部署中的应用[J].传感技术学报,2018,31(5):753-758.
- [7] ZHOU Y Q, ZHAO R X, LUO Q F, et al. Sensor deployment scheme based on social spider optimization algorithm for wireless sensor networks [J]. Neural Processing Letters, 2018,48(1):71-94.
- [8] 张春雨,刘晓东,孙丽君,等.基于主成分分布谷鸟搜索算法的WSN覆盖优化[J].电子测量技术,2021,44(18):129-135.
- [9] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering An Open Access Journal, 2020,8(1):22-34.
- [10] 汤安迪,韩统,徐登武,等.基于混沌麻雀搜索算法的无人机航迹规划方法[J].计算机应用,2021,41(7):2128-2136.
- [11] ZHU Y L, YOUSEFI N. Optimal parameter identification of PEMFC stacks using Adaptive Sparrow Search Algorithm[J]. International Journal of Hydrogen Energy, 2021,46(14):9541-9552.
- [12] 付华,刘昊.多策略融合的改进麻雀搜索算法及其应用[J].控制与决策,2022,37(1):87-96.
- [13] 吕鑫,慕晓冬,张钧,等.混沌麻雀搜索优化算法[J].北京航空航天大学学报,2021,47(8):1712-1720.
- [14] 尹德鑫,张达敏,蔡朋宸,等.改进的麻雀搜索优化算法及其应用[J].计算机工程与科学 2022:1-8.
- [15] WANG S P, YANG X P, WANG X Q, et al. A virtual force algorithm-lévy-embedded grey wolf optimization algorithm for wireless sensor network coverage optimization[J]. Sensors, 2019,19(12):2735-2735.
- [16] 李鹏,丁倩雯.基于麻雀算法优化的OSTU分割算法[J].电子测量技术,2021,44(19):148-154.

#### 作者简介

陈立万,教授,硕士研究生导师,主要研究方向为电子系统级(ESL)设计、无线传感器网络等领域。

E-mail:CLW164@126.com

赵尚飞,硕士研究生,主要研究方向为智能优化算法,无线传感器网络覆盖优化。

E-mail:fei1396706112@163.com

曾蝶,硕士研究生,主要研究方向为智能优化算法,无线传感器网络覆盖优化。

E-mail:die\_066390@163.com

欧俊,硕士研究生,主要研究方向为无线传感器网络。

E-mail:1531599523@qq.com

崔浩,硕士研究生,主要研究方向为无线传感器网络。

E-mail:ch15523701566@163.com