

DOI:10.19651/j.cnki.emt.2211002

多策略灰狼算法在 WSN 上的覆盖优化研究^{*}曾蝶¹ 陈立万² 赵尚飞¹ 袁浩¹ 吴天文¹

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

摘要: 针对随机部署无线传感网络出现的覆盖率低的问题,提出了一种多策略灰狼(MSGWO)算法的无线传感网络覆盖优化方法。首先,为平衡全局与局部搜索,提出双曲正切的非线性收敛因子;其次,采用差分变异重构包围步长来降低算法陷入局部最优的概率;然后,为加快算法的收敛速度与精度,利用瞬态搜索优化方程更新灰狼位置;接着融合莱维飞行策略增加空间搜索多样性;最后,引入边界越位策略避免灰狼个体越界重定位问题。仿真结果表明,MSGWO算法相比SSA、LGWO、PSO和PSOGWO算法的平均覆盖率增量分别为12.52%、6.054%、7.53%和3.45%,该算法具有较高的平均覆盖率和更优的节点分布状态。

关键词: 双曲正切收敛因子;差分变异重构包围步长;瞬态搜索优化方程;莱维飞行;边界越位

中图分类号: TP393 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Research on coverage optimization of multi strategy grey wolf algorithm on WSN

Zeng Die¹ Chen Liwan² Zhao Shangfei¹ Yuan Hao¹ Wu Tianwen¹

(1. School of Electronic and Information Engineering, Chongqing Three Gorges University, Chongqing 404120, China;

2. Teacher School of Education, Chongqing Three Gorges University, Chongqing 404120, China)

Abstract: Aiming at the problem of low coverage of wireless sensor networks deployed randomly, a Multi Strategy gray wolf (MSGWO) algorithm for wireless sensor network coverage optimization is proposed. Firstly, in order to balance the global and local search, a nonlinear convergence factor of hyperbolic tangent is proposed; Secondly, the bounding step size is reconstructed by differential mutation to reduce the probability of the algorithm falling into local optimization; Then, in order to speed up the convergence speed and accuracy of the algorithm, the gray wolf position is updated by using the transient search optimization equation; Then, Levy flight strategy is integrated to increase the diversity of space search; Finally, the boundary offside strategy is introduced to avoid the relocation of gray wolf individuals. The simulation results show that compared with SSA, LGWO, PSO and PSOGWO, the average coverage increment of MSGWO algorithm is 12.52%, 6.054%, 7.53% and 3.45% respectively. This algorithm has higher average coverage and better node distribution.

Keywords: hyperbolic tangent convergence factor; reconstruction of bounding step size by differential mutation; transient search optimization equation; levy flight; boundary offside

0 引言

无线传感网络(wireless sensor network, WSN)是一种分布式传感网络,凭借其灵活的组建方式,广泛应用于物联网,基于无线传感网络的可靠性、自组织性、动态性和以数据为中心等特点,被认为是影响人类未来生活的重要技术之一^[1]。无线传感网络应用广泛,包括参数估计、环境空

气质量分类、预测、医疗、经济调度、图像处理等方向^[2],伴随无线传感网络的发展,无线传感网络的不足逐渐显现,覆盖率的问题是无线传感网络要解决的一个重要问题。

近年来,研究人员通过各种智能算法以解决无线传感网络出现的覆盖率低的问题。为提高 WSN 的覆盖性能,王毅等^[3]利用水波优化算法对节点坐标进行优化部署,该算法一定程度上提升了监测区域的覆盖率,但在收敛精度

收稿日期:2022-08-08

^{*} 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

方面欠缺。对于 WSN 在节点部署中存在的覆盖空白和重叠覆盖问题,李守玉等^[4]将改进的平衡优化器算法应用于 WSN 覆盖优化,改善了网络覆盖率低的问题,但该算法的对比试验较少,不能充分说明算法的有效性。张春雨等^[5]针对节点高维优化和覆盖区域复杂性,提出一种主成分分布谷鸟搜索算法,该算法有效地提高了监测区域节点的覆盖范围,但缺少算法有效性验证。王振东等人为提高 WSN 节点的有效覆盖率,在文献[6]和[7]中研究到一种增强型麻雀算法和改进的差分进化方法,两种算法都减少了节点冗余和改善节点分布不均现象,然而却缺少对网络寿命的研究。唐菁敏等^[8]从智能算法存在局部极值、收敛精度不高和速度慢等问题入手,研究了一种帝企鹅差分算法,该算法有效地优化了节点分布,并提升网络质量,该算法的稳定性及多场景适用情况有待验证。对于传感器节点随机部署时聚集度高和覆盖率低的问题,Zhang 等^[9]建立无线传感器网络覆盖优化的数学模型,将模拟退火算法嵌入到灰狼中,该算法主要研究了静态节点,没有考虑到移动节点的无线传感网络优化问题。Lu 等^[10]对于同构网络中移动节点随机抛洒造成的覆盖空洞问题提出了一种基于修补优先级的改进算法。该算法在 Voronoi 多边形的帮助下确定覆盖空洞大小,能有效提升整个网络的覆盖范围,但该算法缺乏有效性与稳定性验证。朱利民等^[11]针对 WSN 的节点覆盖模型弊端,在能量有限的情况下,提出了一种改进自适应遗传算法,该算法考虑到节点的移动方式,结果表明与其他模型相比,具有更长的生存周期。郭超等^[12]针对节点的覆盖方式和分布情况进行研究,将拟库仑力和拟万有引力融入粒子群,减少了算法重复覆盖。但该算法无法平衡全局与局部搜索,容易陷入局部极值。研究者们基于改进的智能算法解决无线传感网络覆盖率低的问题做了深入研究,但仍然存在算法收敛精度不高,未对算法做进一步验证性说明等缺点,这也间接导致应用于无线传感网络覆盖优化上覆盖率提升不明显的问题。

综上所述,无线传感网络覆盖率低的问题一直是首要解决的关键问题,不同的智能优化算法应用于无线传感网络覆盖优化上较标准算法覆盖率有所提升,但整体优势不明显,但不可否认智能算法对于无线传感网络覆盖率提升的贡献。灰狼算法是由 Mirialili 等^[13]于 2014 年提出的一种模仿灰狼社会等级的新型群体智能优化算法。和其它智能算法一样灰狼算法存在迭代后期种群多样性减小、求解精度不高、收敛速度较慢和易陷入局部极值等问题,基于此提出混沌映射以丰富种群多样性;双曲正切收敛因子增加全局与局部搜索能力;差分变异重构包围步长促进前三等级灰狼的信息交流;结合瞬态搜索优化(transient search optimization, TSO)算法以扩大灰狼算法搜索范围;莱维飞行增加区域搜索的多样性。融合多种策略,提出了一种多策略的灰狼算法(multi strategy grey wolf optimizer, MSGWO),并将其应用于无线传感网络覆盖优化,以提高

网络覆盖率。

1 WSN 覆盖模型

在监测区域中随机抛洒 N 个传感器节点,形成传感器节点集 $K = \{k_1, k_2, k_3, \dots, k_N\}$, 第 i 个节点的坐标为 $k_i(x_i, y_i)$ 。监控节点集合 $L = \{l_1, l_2, l_3, \dots, l_N\}$, 监测区域内目标点坐标为 $l_u(x_u, y_u)$, 监控点与目标点的距离为:

$$d(k_i, l_u) = \sqrt{(x_i - x_u)^2 + (y_i - y_u)^2} \quad (1)$$

若 $d(k_i, l_u) \leq R_1$, 则目标点在覆盖区域内,感知度记为 1;反之,则在覆盖区域之外,感知度记为 0。采用布尔感知模型,感知度为:

$$p(k_i, l_u) = \begin{cases} 1, & d(k_i, l_u) \leq R_1 \\ 0, & d(k_i, l_u) > R_1 \end{cases} \quad (2)$$

为准确评估 WSN 的覆盖率,将整个监测区域划分成 $m \times n$ 个像素,若覆盖到 M 个点,那么存在覆盖率为 $M/(m \times n)$ 。网络覆盖率 R_{cov} 为:

$$R_{cov} = \frac{\sum_{x=1}^c \sum_{y=1}^w R_p(k_{all}, l_u)}{K} \quad (3)$$

以覆盖率为适应度函数,可以检验无线传感网络覆盖性能。监测区域面积为 K , 划分为等面积 $C \times W$ 的网格,规定每个网格的中心为监测点 l , 以此来计算监测概率。其中 k_{all} 是测量区域内所有待测节点, $R_p(k_{all}, l_u)$ 为联合感知概率,表达式为:

$$R_p(k_{all}, l_u) = 1 - \prod_{i=1}^n (1 - p(k_i, l_u)) \quad (4)$$

2 MSGWO 算法

在 GWO 算法中,为构建灰狼的社会等级制度模型,将种群中适应度值最优解、次优解和第三优解分别看作 α 狼、 β 狼和 δ 狼,而剩余的解被视为 ω 狼。在 d 维搜索空间中,假设 N 只灰狼个体组成种群 $G = G(G_1, G_2, G_3, \dots, G_N)$, 第 I 只灰狼的位置为 $G_I = G(G_I^1, G_I^2, G_I^3, \dots, G_I^d)$ 。

首先描述灰狼逐渐包围猎物的数学模型,第 I 只狼有 $G_I^d(t+1) = G_p^d(t) - A_I^d | C_I^d G_p^d(t) - G_I^d(t) |$ 。其中 t 为当前迭代次数, $G_p = G(G_p^1, G_p^2, G_p^3, \dots, G_p^d)$ 为猎物位置, $A_I^d | C_I^d G_p^d(t) - G_I^d(t) |$ 为包围步长。其中 A_I^d 与 C_I^d 分别表示为:

$$A_I^d = 2a \cdot r_1 - a \quad (5)$$

$$C_I^d = 2 \cdot r_2 \quad (6)$$

A_I^d 的值也会随着控制参数的减少而减少,其中 A_I^d 是区间 $[-a, a]$ 内的随机值。式(5)与(6)中 r_1 和 r_2 为 $[0, 1]$ 区间上的随机数,其中控制参数为 $a = 2 - 2t/t_{max}$, 从 2 至 0 线性递减,随当前迭代次数 t 的变化而变化, t_{max} 为最大迭代次数。在 GWO 算法中,传感器的位置由 α 狼、 β 狼和 δ 狼的位置决定,式(7)是 α 狼、 β 狼和 δ 狼的位置更新公式:

$$G_{1,\alpha/\beta/\delta}^d(t+1) = G_{\alpha/\beta/\delta}^d(t) - A_{1,1/2/3}^d | C_1^d G_{\alpha/\beta/\delta}^d(t) - G_1^d(t) | \quad (7)$$

$$G_{1,all}^d(t+1) = \frac{\sum_{j=\alpha,\beta,\delta} G_{1,j}^d(t+1)}{3} \quad (8)$$

其中, α 狼、 β 狼和 δ 狼的包围步长整体表示为 $D_{1,\alpha/\beta/\delta}^d(t+1) = A_{1,1/2/3}^d | C_1^d G_{\alpha/\beta/\delta}^d(t) - G_1^d(t) |$ 。

2.1 混沌映射初始化种群

混沌序列具有普适性、非线性、遍历性和随机性等特点,为了能够丰富灰狼种群的多样性,利用 Tent 混沌映射初始化种群,可以增加种群多样性。Tent 映射在数学表达式上为分段的线性映射,具有较好的混沌扰动能力。相比 Logistic 映射,Tent 映射具有更加均匀的概率密度和理想的相关特性,更快的迭代次数,普遍适用于智能优化算法。该映射的数学表达式如(9)所示。

$$T(x_n) = \begin{cases} \frac{x_n}{\sigma}, & x_n \in [0, \sigma] \\ \frac{1-x_n}{1-\sigma}, & x_n \in [\sigma, 1] \end{cases} \quad (9)$$

其中, σ 取 $[0, 1]$ 上的随机数,当取 0.5 时处于较好的混沌状态^[14]。

2.2 双曲正切收敛因子

为了建立靠近猎物的数学模型,设置了收敛因子,线性减少收敛因子的值来保证模型的运行。灰狼算法的收敛因子是线性的,由于GWO算法寻优的复杂性,收敛因子线性递减已经不能满足实际的寻优过程,文献[15]和[16]都提出了改进的非线性收敛因子,采用非线性收敛因子获得了更好的寻优结果,基于非线性参数的优势,提出了一种融合双曲正切的非线性收敛因子:

$$a_1 = 2\cos\left(\frac{u^2}{l_{\max}} \cdot \frac{\pi}{2}\right), u = \tanh\left(\pi \frac{(t_{\max} - t)}{t_{\max}}\right) \quad (10)$$

将迭代次数与最大迭代次数融入双曲正切函数,可以动态调整分布,并且具有自学习进化规律。非线性控制参数迭代前期递减速度较慢,可以延长算法陷入局部最优的速度,同时增加了全局搜索能力;迭代后期递减速度相对较快,加快算法寻优,可以改善局部搜索。

2.3 差分变异重构包围步长

灰狼算法初期的包围步长都是没有经过筛选的,利用差分变异重构包围步长不断提高选择前三等级灰狼的机率,促进前三等级灰狼的信息交流,其数学模型如式(11)~(14)所示:

$$D_{1,\alpha}^d(t+1) = \frac{(D_{1,\alpha}^d(t) + D_{1,\beta}^d(t))}{2} \quad (11)$$

$$D_{1,\beta}^d(t+1) = \frac{(D_{1,\alpha}^d(t) + D_{1,\beta}^d(t) + D_{1,\delta}^d(t))}{3} \quad (12)$$

$$D_{1,\delta}^d(t+1) = \begin{cases} D_{1,\alpha}^d(t) + \mu \times (|D_{1,\alpha}^d(t) - D_{1,\beta}^d(t)|), & t \leq \frac{t_{\max}}{2} \\ D_{1,\beta}^d(t) + \mu \times (|D_{1,\alpha}^d(t) - D_{1,\delta}^d(t)|), & t > \frac{t_{\max}}{2} \end{cases} \quad (13)$$

$$\mu = (t/t_{\max}) \cdot \tanh(1 - t/t_{\max}) \cdot \psi \quad (14)$$

其中, $D_{1,\alpha}^d(t), D_{1,\beta}^d(t), D_{1,\delta}^d(t)$ 为算法初期 3 个最优包围步长, $D_{1,\delta}^d(t+1)$ 就是通过这 3 个最优包围步长来降低算法陷入局部最优的概率。在差分变异的过程中, μ 为尺度因子,其中 ψ 为调节因子,其值为 3,以便控制曲线的平滑度。

2.4 瞬态搜索优化方程

GWO 算法的寻优结果与 α 狼、 β 狼和 δ 狼的位置有关,如果存在位置不理想的情况,就容易误导其他狼,使整个狼群陷入局部最优,算法后期搜索能力差,容易早熟。其次算法位置更新采用了整体更新机制,对于可分离变量函数来说,其中解向量的优化方向很难与每一维方向一致,从而降低了算法的搜索效率。灰狼算法存在诸多局限,而瞬态搜索优化方程具有鲁棒性高和方程简易灵活的特点,将瞬态搜索优化算法^[17]融入灰狼算法位置更新方程,提出一种分段的瞬态搜索方程改进后期搜索能力差的问题,并提高搜索效率。对于 α 狼,位置更新方程为:

$$Y = e^{-T} [\cos(2\pi T) + \sin(2\pi T)] \quad (15)$$

$$\begin{cases} x_{d1}^{t+1}(t+1) = D_{1,\alpha}^d(t) + D_{1,\alpha}^d(t) \times e^{-T}, & rand < 0.5 \\ x_{d1}^{t+1}(t+1) = D_{1,\alpha}^d(t) + Y \times |D_{1,\alpha}^d(t)|, & rand \geq 0.5 \end{cases} \quad (16)$$

其中, $rand$ 是 $0 \sim 1$ 上的随机数, T 和 C 是随机系数,如式(17)和(18)所示。

$$T = 2a_1 \times rand - a_1 \quad (17)$$

$$C = k \times a_1 \times rand + 1 \quad (18)$$

k 为 $[0, 1, 2, \dots]$ 上的常数,取 2,对于 β 狼,位置更新方程为:

$$\begin{cases} x_{d2}^{t+1}(t+1) = D_{1,\beta}^d(t) + D_{1,\beta}^d(t) \times e^{-T}, & rand < 0.5 \\ x_{d2}^{t+1}(t+1) = D_{1,\beta}^d(t) + Y \times |D_{1,\beta}^d(t)|, & rand \geq 0.5 \end{cases} \quad (19)$$

对于 δ 狼,位置更新方程为:

$$\begin{cases} x_{d3}^{t+1}(t+1) = D_{1,\delta}^d(t) + D_{1,\delta}^d(t) \times e^{-T}, & rand < 0.5 \\ x_{d3}^{t+1}(t+1) = D_{1,\delta}^d(t) + Y \times |D_{1,\delta}^d(t)|, & rand \geq 0.5 \end{cases} \quad (20)$$

瞬态搜索方程通过随机系数 T 平衡全局与局部搜索,当 $T < 0$ 时,瞬态搜索将会保持较大的振幅搜索最佳灰狼位置,全局搜索能力强;当 $T > 0$ 时,瞬态搜索达到稳态,局部开发能力强,进而提升算法收敛速度与精度。为了解决算法过早收敛问题,根据 α 狼、 β 狼和 δ 狼的包围步长对 ω 狼,进行动态加权变异,变异方程系数为:

$$W_{\alpha_1, \beta_1, \delta_1} = \frac{D_{1,\alpha,\beta,\delta}^d(t)}{D_{1,\alpha}^d(t) + D_{1,\beta}^d(t) + D_{1,\delta}^d(t)} \quad (21)$$

对包围步长动态加权,得到的加权解优于 GWO 算法解,可以加快算法的收敛速度,对于 ω 狼,位置更新方程为:

$$x_{d1}^{t+1}(t+1) = \frac{W_{\alpha_1} \cdot x_{d1}^{t+1} + W_{\beta_1} \cdot x_{d2}^{t+1} + W_{\delta_1} \cdot x_{d3}^{t+1}}{3} \quad (22)$$

该方法不仅加快了 ω 狼的更新速度,还间接影响了其余狼的搜索方向,改进了算法陷入局部极值的困境,加快了算法搜索速度。

2.5 莱维飞行策略

莱维飞行是通过随机游动描绘莱维稳定分布的方法,大量研究表明,许多昆虫与动物的行为可以表征莱维飞行的特征。在改进的灰狼位置更新方程基础上,引入莱维飞行公式:

$$x_{all}(t+1) = \begin{cases} rand \times Q + \alpha \oplus levy(\beta), & |rand| \geq 0.5 \\ rand \times Q, & |rand| < 0.5 \end{cases} \quad (23)$$

其中, Q 表示前 3 个灰狼最优位置, $\alpha \oplus levy(\beta)$ 表示随机搜索路径。随机搜索路径如式 (25) 所示, $rand$ 为 $0 \sim 1$ 上的随机数, $x_{all}(t+1)$ 为莱维飞行之后的最佳位置。

$$Q = x_{d1}^{t+1}(t+1) + x_{d2}^{t+1}(t+1) + x_{d3}^{t+1}(t+1) \quad (24)$$

$$\alpha \oplus levy(\beta) \sim 0.01 \frac{u}{|v|^{-\beta}}(x(t) - G_{l,all}^d(t+1)) \quad (25)$$

其中, u 和 v 服从正态分布:

$$u \sim N(0, \sigma_u^2), v \sim N(0, \sigma_v^2) \quad (26)$$

σ_u 和 σ_v 取值如下:

$$\sigma_u = \left[\frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \beta \times 2^{\frac{\beta-1}{2}}}\right]^{\frac{1}{\beta}}, \sigma_v = 1, \beta \in [0, 2] \quad (27)$$

在灰狼算法中引入莱维飞行策略,进一步牵引种群移动,增加在监测区域搜索的多样性。

2.6 边界越位策略

伴随迭代次数的增加, ω 狼也有可能不在灰狼捕猎范围之外,这时就要及时调整 $x_{d1}^{t+1}(t+1), x_{d2}^{t+1}(t+1), x_{d3}^{t+1}(t+1)$ 和 $x_{d4}^{t+1}(t+1)$ 的位置,边界越位策略可以及时调整灰狼位置:

$$\begin{cases} G' = \mu \cdot L_{lower}, & G' < L_{lower} \\ G' = \mu \cdot U_{upper}, & G' > U_{upper} \end{cases} \quad (28)$$

其中, G' 是越界个体的更新位置, μ 为尺度因子,如式(14)所示,其中 L_{lower} 是下界, U_{upper} 是上界。如果灰狼位置低于下界,让下界值与随机数的乘积取代灰狼位置;如果灰狼位置高于上界,让上界值与随机数的乘积取代灰狼位置,即让灰狼位置在上下界之间。

3 MSGWO 算法覆盖优化步骤

如果在目标区域采取随机抛洒节点的方式,会造成覆盖冗余及覆盖率低的问题,为解决该问题,利用混沌映射的方式增加种群多样性。以覆盖率为适应度函数,观察覆盖率作为评判无线传感网络质量的标准,即节点覆盖率 R_{cov} 最大化。

算法优化步骤如下:

步骤 1) 初始化监测区域面积、感知半径 R_1 、节点个数

N 、种群规模 $sizepop$ 、空间维数 dim 、最大迭代次数 t_{max} 。

步骤 2) 预分配种群内存,随机生成初始种群并进行位置初始化。

步骤 3) 通过节点覆盖模型计算覆盖率。

步骤 4) 初始化收敛因子。

步骤 5) 判断 $|A_i^d|$ 是否小于 1, 进而进行全局搜索和局部搜索。

步骤 6) 计算个体当前适应度并对适应值排序,并保存种群最优平均适应度。

步骤 7) 通过节点覆盖模型计算覆盖率。

步骤 8) 根据式(11)~(14)差分变异重构包围步长,再次由式(15)~(22)更新种群的位置 $x_{d1}^{t+1}, x_{d2}^{t+1}, x_{d3}^{t+1}, x_{d4}^{t+1}$, 利用式(10)更新收敛因子。

步骤 9) 采用边界越位策略,确保每个个体在捕猎范围之内。

步骤 10) 根据式(23)~(27)莱维飞行策略增加空间搜索多样性。

步骤 11) 进行边界越位处理。

步骤 12) 判断是否达到最大迭代次数,若满足则算法停止,并输出种群最优解,即覆盖率,否则转到步骤 5)。

4 MSGWO 算法性能测试

4.1 实验环境及参数设置

实验环境采用 Windows10 家庭版 64 位操作系统,英特尔 Intel(R) Core(TM) i5-10500U 3.10 GHz 和 8 G 内存的 PC,编程环境为 Matlab R2020b。

为检验 MSGWO 算法性能,在六种基准函数的标准下进行测试,其函数名、取值范围、最优解和维度如表 1 所示,其中 F1~F3 为高维单峰函数, F4~F6 为高维多峰函数。基于仿真测试的准确性,实验迭代次数为 500 次,种群数量为 30,各算法的收敛曲线、箱线图 and 数值优化结果均在运行 30 次的基础上得到的。选取文献[18-21]的 PSOGWO (grey wolf optimization algorithm based on particle swarm optimization, PSOGWO) 算法、LGWO 算法 (levy-embedded grey wolf algorithm, LGWO)、SSA (sparrow search algorithm, SSA) 和 PSO (particle swarm optimization, PSO) 对比。

表 1 基准函数

函数	函数名	取值范围	f_{min}	维度
F_1	Sphere	$[-100, 100]$	0	30
F_2	Schwefel 1.2	$[-100, 100]$	0	30
F_3	Schwefel 2.21	$[-100, 100]$	0	30
F_4	Quartic	$[-1.28, 1.28]$	0	30
F_5	Rastrigin	$[-5.12, 5.12]$	0	30
F_6	Griewank	$[-600, 600]$	0	30

4.2 收敛性分析

基准函数可以测试算法的收敛精度与速度,如图1(a)~(f)所示,是在6种基准函数测试下的收敛曲线。其中横轴表示迭代次数,纵轴表示适应度值。不论在单峰函数还是多峰函数上,MSGWO算法都具有更快的收敛速度和更高的寻优精度。以F2为例,观察如图1(b),MSGWO算法下降速度最快,说明其求解速度更快,反观SSA算法,迭代次数在约240时才出现拐点。在迭代次数为400次时,MSGWO算法比PSO和PSOGWO算法高约300个数量级,较SSA算法高约220个数量级,较LGWO算法高约285个数量级。

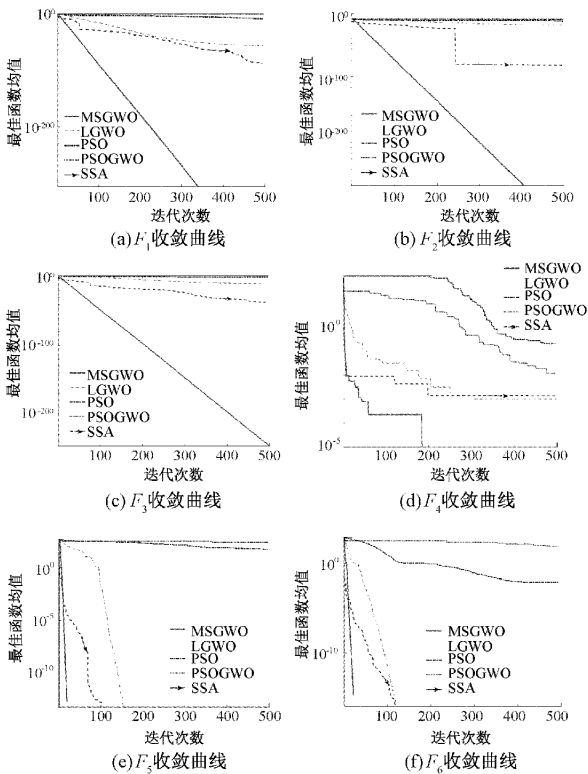


图1 基准函数收敛曲线图

箱线图的主要作用是反应单组数据的分布状态、异常值、稳定性与波动性,对比不同类别数据分布上的差异性。如图2(a)~(f)所示,是6种基准函数的箱线图,其中横轴表示各类算法,纵轴表示适应度值。MSGWO算法的解都集中于最优解附近,拥有更高的收敛精度。各类算法在6种基准函数上普遍存在异常解,而MSGWO算法的异常解相对较少,且离最优解更近,说明MSGWO算法在处理复杂问题时具有更好性能,能够处理好异常解。

从箱线图的高度来看,如图2(a)~(c)和(f)在F1、F2、F3和F6上的箱线图结果,MSGWO算法的箱线图高度最低,说明该算法具有较低的波动性和较高的稳定性;如图2(d)和(e)在F4和F5上的箱线图结果,虽然MSGWO算法的箱线图高度偏高,但与各类算法相比,高度几乎可以

忽略。综上关于MSGWO算法的收敛性分析,该算法的收敛精度、速度和稳定性能最佳。

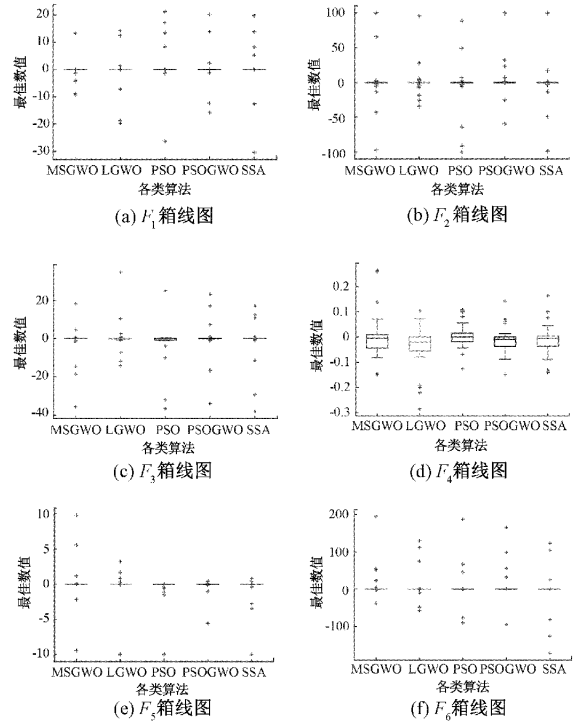


图2 基准函数箱线图

4.3 数值优化结果分析

从表2可知,对于单峰函数F1~F3,MSGWO算法的均值和标准差最佳,尤其是标准差与最优解0一致,表明MSGWO算法具有较高的收敛精度。在F1上PSOGWO算法的标准差和均值分别为14.1283和11.9579,远远偏离最优解,其精度最低;MSGWO算法均值为 3.6175×10^{-165} ,标准差为0,精度最高。在F2和F3上,精度最低的是PSO算法。对于多峰函数F4~F6,MSGWO算法均值与标准差最小,具有较强的稳定性和鲁棒性,在3个多峰函数上,PSO算法的均值和标准差偏离最优解最远,说明粒子群算法的稳定性和鲁棒性最差。

从运行时间来看,从用时最短到用时最长进行排名为PSO>PSOGWO>SSA>MSGWO>LGWO,其中,PSO算法平均运行时间为0.21792s,时间最短,LGWO算法运行时间最长,其平均时间为1.61826s,本文的多策略灰狼算法的平均运行时间为1.30678s,但考虑改进灰狼算法的运行时间在1s左右,相比算法收敛速度与精度的提升来说时间可忽略。

5 WSN覆盖优化仿真实验与分析

5.1 参数设置

多策略灰狼算法具有较强的稳定性和鲁棒性,并且其收敛速度与精度更具优势,将其应用到无线传感网络上,检验改进灰狼算法的WSN覆盖性能,进行仿真实验。仿真

表 2 基准函数数值优化结果

函数	算法	均值	标准差	时间/s
F_1	PSOGWO	11.957 9	14.128 3	0.233 937
	MSGWO	$3.617 5 \times 10^{-163}$	0	1.226 438
	SSA	$1.215 8 \times 10^{-41}$	$6.100 3 \times 10^{-40}$	0.393 954
	LGWO	$7.002 4 \times 10^{-29}$	$7.154 3 \times 10^{-28}$	1.599 368
	PSO	0.001 2	0.001 4	0.107 575
F_2	PSOGWO	0.141 0	0.148 7	0.694 440
	MSGWO	$1.405 6 \times 10^{-163}$	0	1.603 634
	SSA	$2.113 3 \times 10^{-18}$	$1.022 8 \times 10^{-16}$	1.108 711
	LGWO	$3.477 0 \times 10^{-6}$	$7.351 6 \times 10^{-4}$	2.096 579
	PSO	2.283 5	2.852 1	0.592 614
F_3	PSOGWO	0.244 3	0.239 1	0.206 810
	MSGWO	$4.113 2 \times 10^{-249}$	0	1.181 039
	SSA	$2.097 4 \times 10^{-35}$	$3.010 4 \times 10^{-34}$	0.363 975
	LGWO	$1.410 59 \times 10^{-9}$	$1.413 1 \times 10^{-9}$	1.626 056
	PSO	0.729 6	0.789 8	0.114 424
F_4	PSOGWO	0.044 7	0.053 5	0.290 005
	MSGWO	$2.852 6 \times 10^{-6}$	$1.032 6 \times 10^{-5}$	1.303 985
	SSA	0.039 7	0.038 1	0.532 610
	LGWO	$3.135 3 \times 10^{-5}$	0.031 9	1.736 371
	PSO	0.112 5	0.120 4	0.189 151
F_5	PSOGWO	1.176 8	1.433 0	0.284 476
	MSGWO	$1.521 3 \times 10^{-10}$	$1.955 0 \times 10^{-10}$	1.239 688
	SSA	$1.744 1 \times 10^{-9}$	$4.236 0 \times 10^{-9}$	0.429 710
	LGWO	$7.443 8 \times 10^{-10}$	$3.941 5 \times 10^{-9}$	1.657 189
	PSO	1.296 8	1.673 5	0.141 575
F_6	PSOGWO	$6.511 7 \times 10^{-8}$	$7.128 4 \times 10^{-8}$	0.265 409
	MSGWO	$1.125 2 \times 10^{-9}$	$1.363 4 \times 10^{-8}$	1.285 873
	SSA	$1.231 1 \times 10^{-9}$	$1.479 8 \times 10^{-8}$	0.459 923
	LGWO	$3.829 9 \times 10^{-9}$	$2.006 9 \times 10^{-8}$	1.486 962
	PSO	0.002 4	0.004 0	0.162 197

参数设置如表 3 所示,对比算法仍然采用文献[18-21]的算法进行验证。

表 3 仿真参数设置

符号	参数	取值
K	目标区域	50 m×50 m
N	传感器节点数	45
$sizepop$	种群规模	50
R_1	节点感知半径(m)	5
t_{max}	最大迭代次数	500
dim	空间维度	2

5.2 WSN 覆盖优化

仿真参数统一设置如表 1 所示,在 30 次实验的基础上,

得到如图 3 所示的平均覆盖优化结果,并分析对比 5 种算法的覆盖性能。如图 3 所示是节点个数为 45 个时的 5 种算法 WSN 节点分布图,其中‘.’代表的是 WSN 节点,以节点感知半径围成的圆表示节点感知区域。观察图 3(b)~(e)的覆盖优化部署结果,发现传感器节点分布不均,并且部分节点重叠区域面积和未覆盖区域面积较大,但相比初始节点部署来说,图 3(b)~(e)的覆盖优化部署结果有明显改善,而图 3(f)的 MSGWO 算法的覆盖效果最好,节点分布较均匀,未覆盖区域面积也最小。从覆盖面积大小看,覆盖效果排名为 MSGWO>PSOGWO>PSO>LGWO>SSA。

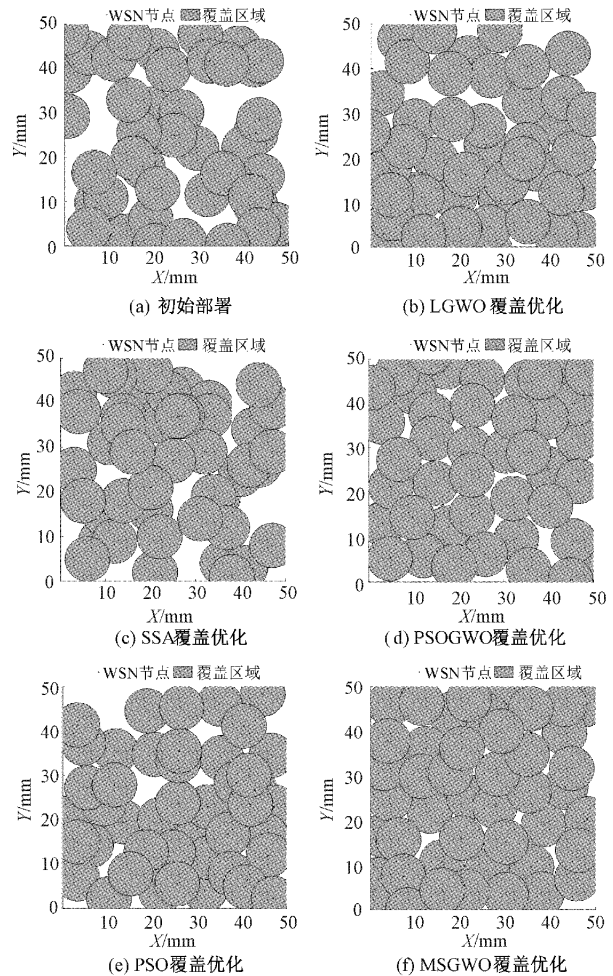


图 3 覆盖优化部署结果

相较于初始覆盖率来说,平均覆盖率最大的是本文所提出的多策略灰狼算法。究其原因,是由于优化前期利用混沌映射增加了种群的多样性;瞬态搜索优化方程更新灰狼位置加快算法的收敛速度与精度;差分变异重构包围步长促进前三等级灰狼信息交流;莱维飞行策略增加了空间搜索多样性。

图 4 是改进多策略算法优化后与各类算法的覆盖率收敛曲线对比图,在规定迭代次数为 500 的前提下,各算法的平均覆盖率都有所增加,标准 SSA 算法在迭代约 200 次时

平均覆盖率达到 84.09%，此时该算法的覆盖率已不再增长，即迭代后期一直未跳出局部最优；LGWO 算法在迭代前期覆盖率增长稍快，但迭代后期平均覆盖率增长缓慢，在达到设定的迭代次数时，平均覆盖率为 90.56%；对于 PSO 算法迭代前期可以保证较高的平均覆盖率增量，在迭代次数约为 200 时平均覆盖率达到 89.08%；其次收敛效果较好的就是 PSOGWO 算法，在 500 代左右达到了最大平均覆盖率，其平均覆盖率为 93.16%。覆盖效果最好的就是 MSGWO 算法，其平均覆盖率在迭代约 500 次就达到了 96.61%。




图4 覆盖率对比图

表4所示是固定剩余仿真参数(括号内为迭代次数)，仅改变迭代次数而得出5种算法的平均覆盖率关系。在同等测试条件下，以迭代次数为500次为例，MSGWO相比SSA、LGWO、PSO和PSOGWO算法的平均覆盖率增量分别为12.52%、6.054%、7.53%和3.45%。总的来看随着迭代次数的增加，各算法的平均覆盖率都有所提升，但MSGWO算法的平均覆盖率增量最大，验证算法的有效性。

表4 迭代次数与平均覆盖率关系

算法	平均覆盖率(250)	平均覆盖率(500)
PSOGWO	0.914 0	0.931 6
MSGWO	0.939 6	0.966 1
SSA	0.808 1	0.840 9
LGWO	0.897 2	0.905 6
PSO	0.880 8	0.890 8
算法	平均覆盖率(750)	平均覆盖率(1 000)
PSOGWO	0.940 8	0.944 8
MSGWO	0.970 4	0.971 6
SSA	0.852 2	0.855 8
LGWO	0.911 2	0.932 8
PSO	0.900 1	0.904 7

图5与6是感知半径、节点个数与平均覆盖率的关系图。如图5所示，5种算法的平均覆盖率都随着节点个数

增加而增加，当节点个数到达55个时，5种算法的平均覆盖率几乎不再增加。对于MSGWO算法，当节点个数超过55个时覆盖率接近1。如图6所示，随着节点感知半径增加，五种算法的平均覆盖率也随之增加。在不同节点个数和不同感知半径条件下，MSGWO算法的平均覆盖率均最高，该算法可以实现更高的网络覆盖率。




图5 感知半径与平均覆盖率关系




图6 节点个数与平均覆盖率关系

综上所述，在相同的环境下测试，SSA、LGWO、PSO和PSOGWO算法的稳定性与鲁棒性不如MSGWO算法，将该MSGWO算法应用于无线传感网络覆盖上，改进多策略灰狼算法平均覆盖率增量最佳，覆盖性能与节点分布状态更好。

6 结 论

针对复杂环境的WSN覆盖低和节点分布不均问题，研究了基于多策略改进灰狼算法的无线传感网络覆盖优化问题。通过引入双曲正切函数描述收敛因子，增加迭代次数的非线性变化，以协调MSGWO算法的局部开发和探索能力；差分变异重构包围步长不断促进前三等级灰狼的信息交流；瞬态搜索方程引导灰狼种群靠近头狼，指导灰狼进化，提高算法收敛速度与精度；莱维飞行策略增加了空间搜索多样性；进行边界越位处理，防止灰狼越界，增加了灰狼在捕猎范围内寻找猎物的机会，进而提高了算法精度。仿真结果显示，在六种基准函数的测试下，MSGWO算法具

有收敛速度快、收敛精度高、较低的波动性和较强的稳定性与鲁棒性。将 MSGWO 算法应用于无线传感网络,在同一测试环境下该算法具有更优的平均覆盖率值,同时节约了网络部署成本。下一步将继续优化算法性能,将覆盖率、节点移动路径和能耗结合起来,综合分析算法性能。

参考文献

- [1] JAISWAL K, ANAND V. A QoS aware optimal node deployment in wireless sensor network using grey wolf optimization approach for IoT applications [J]. Telecommunication Systems, 2021, 78(4): 559-576.
- [2] LIANG D, SHEN H, CHRN L. Maximum target coverage problem in mobile wireless sensor networks[J]. Sensors(Basel, Switzerland), 2020, 21(1): 184.
- [3] 王毅, 神显豪, 唐超尘, 等. 基于水波优化算法的无线传感器网络覆盖研究[J]. 南京理工大学学报, 2021, 45(6): 680-686.
- [4] 李守玉, 何庆, 陈俊. 改进平衡优化器算法的 WSN 覆盖优化[J]. 计算机应用研究, 2022, 39(4): 1168-1172, 1189.
- [5] 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.
- [6] 王振东, 汪嘉宝, 李大海. 一种增强型麻雀搜索算法的无线传感器网络覆盖优化研究[J]. 传感技术学报, 2021, 34(6): 818-828.
- [7] 王振东, 刘燧桃, 胡中栋, 等. 改进差分进化算法下的无线传感器网络覆盖优化[J]. 小型微型计算机系统, 2020, 41(5): 1041-1046.
- [8] 唐菁敏, 曲文博, 苏慧慧, 等. 一种基于帝企鹅差分算法的 WSN 覆盖优化[J]. 云南大学学报(自然科学版), 2021, 43(1): 46-51.
- [9] ZHANG Y, CAO L, YUE Y, et al. A novel coverage optimization strategy based on grey wolf algorithm optimized by simulated annealing for wireless sensor networks [J]. Computational Intelligence and Neuroscience, 2021, 2021(1): 1-14.
- [10] LU X, SU Y, WU Q, et al. An improved coverage gap fixing method for heterogenous wireless sensor network based on Voronoi polygons [J]. AEJ-Alexandria Engineering Journal, 2021, 60 (5): 4307-4313.
- [11] 朱利民, 赵丽. 基于改进自适应遗传算法的移动 WSN 覆盖方法[J]. 计算机应用研究, 2019, 36(5): 1510-1514.
- [12] 郭超, 杨宇轩, 胡荣磊, 等. 基于粒子群算法的 WSN 覆盖优化[J]. 计算机应用研究, 2020, 37(4): 1170-1173, 1182.
- [13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61, DOI:10.1016/j.advensoft.2013.12.007.
- [14] 王贺琦, 王然, 刘诗琳, 等. 基于 Tent 映射的改进型人工蜂群算法[J]. 软件工程, 2022, 25(8): 15-19.
- [15] WANG Z, XIE H, HU Z, et al. Node coverage optimization algorithm for wireless sensor networks based on improved grey wolf optimizer[J]. Journal of Algorithms and Computational Technology, 2019, 13, DOI:10.1177/1748302619889498.
- [16] WEN L. Grey wolf optimizer based on nonlinear adjustment control parameter [C]. 2016 4th International Conference on Sensors, Mechatronics and Automation (ICSMA 2016), 2016, 136: 643-648, DOI:10.2991/ICSMA-16.2016.111.
- [17] QAIS M H, HASANIEN H M, ALGHUWAINEM S. Transient search optimization: A new meta-heuristic optimization algorithm[J]. Applied Intelligence, 2020, 50: 3926-3941, DOI:10.1007/s10489-020-01727-y.
- [18] 吕金玲. 基于灰狼优化算法的无线传感器网络覆盖策略[D]. 吉林: 东北电力大学, 2019.
- [19] HEIDARI A A, PAHLAVANI P. An efficient modified grey wolf optimizer with levy flight for optimization tasks[J]. Applied Soft Computing, 2017, 60: 115-134, DOI:10.1016/j.asoc.2017.06.044.
- [20] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [21] 史朝亚. 基于 PSO 算法无线传感器网络覆盖优化的研究[D]. 南京: 南京理工大学, 2013.

作者简介

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。

陈立万(通信作者), 硕士, 教授, 硕士研究生导师, 主要研究方向为电子系统级(ESL)设计、信号与信息处理、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。

袁浩, 硕士研究生, 主要研究方向为无线传感器网络。

吴天文, 硕士研究生, 主要研究方向为无线传感器网络。