

DOI:10.19651/j.cnki.emt.2210624

基于 EGWOEO 算法的三维无线传感网络覆盖优化*

陈立万¹ 曾蝶² 赵尚飞² 袁浩² 吴天文²

(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: 针对三维随机部署无线传感网络节点出现的覆盖率低和节点不均现象,以覆盖率为适应度函数,提出一种基于 EGWOEO 算法的三维无线传感网络覆盖优化算法。首先,采用 Tent 混沌映射初始化种群,以增加种群多样性;其次,利用反向学习策略,以增加全局搜索能力;之后,融入双曲正切高斯策略,加强算法寻优能力;然后,提出一种正弦函数的非线性收敛因子,以平衡全局与局部搜索;最后,改进种群位置更新方程,加快算法的收敛速度与精度。将改进的 EGWOEO 算法应用于三维 WSN 覆盖优化中,仿真结果表明,与 GWO、PSOGWO、LGWO 算法相比,EGWOEO 算法的三维 WSN 覆盖率平均增量分别为 11.023%、10.662% 和 12.401%,改善了节点分布不均现象,提高了节点利用率。

关键词: 混沌映射;反向学习;双曲正切高斯函数;位置更新;三维覆盖优化

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

Coverage optimization of 3D wireless sensor networks based on EGWOEO algorithm

Chen Liwan¹ Zeng Die² Zhao Shangfei² Yuan Hao² Wu Tianwen²

(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: Aiming at the phenomenon of low coverage and uneven nodes in three-dimensional wireless sensor networks with random deployment, taking the coverage as the fitness function, a coverage optimization algorithm for three-dimensional wireless sensor networks based on EGWOEO algorithm is proposed. Firstly, tent chaotic map is used to initialize the population to increase the diversity of the population. Secondly, reverse learning strategy is used to increase the global search ability. Thirdly, the hyperbolic tangent Gaussian strategy is integrated to strengthen the optimization ability of the algorithm. Then, a nonlinear convergence factor of sine and cosine function is proposed to balance the global and local search. Finally, the population position update equation is improved to speed up the convergence speed and accuracy of the algorithm. The improved EGWOEO algorithm is applied to 3D WSN coverage optimization, the simulation results show that compared with GWO, PSOGWO and LGWO algorithms, the average increment of 3D WSN coverage of EGWOEO algorithm is 11.023%, 10.662% and 12.401% respectively, which improves the uneven distribution of nodes and improves the utilization of nodes.

Keywords: chaotic mapping; reverse learning; hyperbolic tangent gaussian function; location update; 3D coverage optimization

0 引言

无线传感网络(wireless sensor network, WSN)在智能交通、智能农业、医疗健康、工业监测和军事上应用广泛^[1]。伴随着 WSN 应用场景的不同,无线传感网络的应

用也会有区别。近年来,无线传感网络覆盖优化成为研究的热点。在监测区域中,传感器节点的部署数量和分布状态对网络服务质量影响很大,如何利用最少的节点个数实现最大的覆盖率,同时保证节点分布均匀性,一直是 WSN 研究的重点。在二维平面,无线传感网络在覆盖率方面近

收稿日期:2022-07-09

*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

乎完善。黄晓璐等^[2]考虑节能与覆盖问题,从节点连通性和寿命入手改善了覆盖率低的问题。Khalaf 等^[3]采用蜜蜂算法以最少节点实现了最大覆盖率。张伟等^[4]利用遗传算法与概率感知的不相交集覆盖模型实现了更高网络覆盖率。Qi 等^[5]提出一种嵌入虚拟力的粒子群优化算法,该算法加快了收敛速度,具有更高的覆盖率。

在无线传感网络发展过程中,二维平面及感知模型无法适应实际应用场景,节点在三维空间的部署研究刻不容缓,研究人员在 WSN 三维空间覆盖优化问题上做了深入研究。吴帅等^[6]提出了一种面向三维的 WSN 覆盖增强算法,该算法在基于智能算法的基础上利用集合覆盖模型找到冗余节点,并移动至未覆盖区域,最终达到增强覆盖率的效果,但是该算法单纯讨论了冗余节点与覆盖率的关系,缺乏与其它算法的对比性验证。对于融合算法的研究,孙爱晶等^[7]探讨了一种基于融合算法的三维覆盖方法,这种融合算法基于优势互补原则,结合了虚拟力与人工鱼群算法提高三维网络的覆盖率问题,但该融合算法缺少收敛性分析。Priyadarshi 等^[8]推导传感器节点半径与覆盖率关系,提出一种基于立方体的三维覆盖模式和部署结构以最大化覆盖率,但该算法没有考虑到节点均匀性问题。刘惠等^[9]结合虚拟力算法研究了三维 WSN 重部署算法,该算法仅对虚拟力的参数设置进行了定性分析。郝占军等^[10]对于现实环境中出现的复杂空间监测问题,提出了一种基于多移动节点的 WSN 三维覆盖算法。该算法首先进行覆盖空洞的检测,找出最优路径,调整移动节点位置,实现对目标监测点的全覆盖。Lil 等^[11]为解决三维无线传感网络数据传输问题,建立了数据集优化模型以权衡节点覆盖率和寿命,该模型时间复杂度高,有待进一步优化。党小超等^[12]提出了一种半径可调节的三维 WSN 覆盖算法,该算法基于虚拟力的节点均匀分布,通过判断节点和目标点的距离,实现半径动态可调,但该算法缺少能耗分析。周挺^[13]针对三维空间出现的覆盖性能差、能耗大等缺点,提出了一种基于虚拟力的三维覆盖增强算法。该算法利用覆盖因子避免节点的无效移动,但对比实验较少,有效性有待进一步验证。

以上无线传感网络三维空间覆盖优化研究表明,大多数研究重点是如何提高无线传感网络覆盖率;其次是将网络覆盖率、网络寿命、数据传输和能耗结合讨论;很少有研究单独考虑三维空间的节点均匀性和覆盖率问题,单纯以覆盖率的提升,验证节点均匀性不具说服力,尤其在解决均匀性问题上缺乏针对性研究。基于这个问题提出一种混合算法(enhanced grey wolf optimizer and equilibrium optimizer, EGWOEO)的三维覆盖算法以解决 WSN 覆盖率和节点均匀性问题。无线传感网络要因地制宜部署传感器节点,考虑在 WSN 三维空间随机抛洒传感器节点带来的覆盖率低和节点分布不均问题,通过混沌映射在三维空间中初始部署节点位置,增强节点的随机性与多样性。改

进平衡算法具有执行效率高和全局寻优能力强的特点,改进的灰狼算法具有求解精度高、收敛速度快、平衡全局与局部搜索和避免陷入局部最优的优势,融合两种算法,优势互补。对于节点均匀性问题,利用改进平衡算法的均衡池平衡节点位置,基本思想就是从均衡池中选择一个候选解为 EGWOEO 算法提供判断平衡状态的依据,以改进节点分布均匀性问题,从而间接提高无线传感网络覆盖率。

1 EGWOEO 算法三维覆盖模型与假设

1.1 三维覆盖模型

由于节点随机抛洒,而传感器节点的分布情况会影响网络覆盖率,以 R_{cov} 作为覆盖率评价标准。在三维覆盖区域中,传感器节点的覆盖区域是某一半径确定的球。在三维监测区域中随机抛洒 N 个传感器节点,形成节点集 $S = \{s_1, s_2, s_3, \dots, s_N\}$, 第 i 个节点的坐标为 $s_i(x_i, y_i, z_i)$ 。三维监控节点集合 $L = \{l_1, l_2, l_3, \dots, l_N\}$, 三维监测区域内目标点为 $l_v(x_v, y_v, z_v)$, 三维监控点与目标点的距离为:

$$d(s_i, l_v) = \sqrt{(x_i - x_v)^2 + (y_i - y_v)^2 + (z_i - z_v)^2} \quad (1)$$

若 $d(s_i, l_v) \leq R_s$, 则目标点在三维覆盖区域内,感知度标记为 1;相反,则在三维覆盖区域之外,感知度标记为 0。采用布尔感知模型,感知度为:

$$p(s_i, l_v) = \begin{cases} 1, & d(s_i, l_v) \leq R_s \\ 0, & d(s_i, l_v) > R_s \end{cases} \quad (2)$$

其中, R_s 为节点的通信半径,假设三维网络中有 k 个待测节点 $s_1, s_2, s_3, \dots, s_k$, 对应点 l 的覆盖率分别为 $p(s_i, l_v)$ 其中 k_{all} 是监测区域内所有待测传感器节点, $R_p(k_{all}, l_v)$ 为联合感知概率,表达式为:

$$R_p(k_{all}, l_v) = 1 - \prod_{i=1}^k (1 - p(s_i, l_v)) \quad (3)$$

网络整体覆盖率为:

$$R_{cov} = \frac{\sum_{i=1}^k R_p(k_{all}, l_v)}{k} \quad (4)$$

其中, R_{cov} 是传感器网络的整体覆盖率, P 为区域中的任意一个监测点。以覆盖率为适应度函数,可以检验无线传感网络覆盖性能。

1.2 三维覆盖模型假设

以下是三维覆盖模型的假设。首先,选用的传感器节点都采用布尔模型,每个节点的感知半径均相等且通信半径均相等,并且满足通信半径是感知半径的两倍条件。其次,每个传感器节点都有自己的三维坐标,节点的监测范围都是以节点坐标为圆心,以感知半径 R_s 为半径的球。最后,假设所有节点具有足够的能量。

2 EGWOEO 算法

在三维空间中,节点均匀性问题尤为突出,平衡优化

(equilibrium optimizer, EO)算法就是通过均衡池来调节节点位置的,使节点排布更加均匀。通过改进的灰狼算法,来提升算法的收敛速度与精度,寻找到最优种群,即寻求最优覆盖。两个算法结合可以有效提高无线传感网络覆盖率。

2.1 混沌映射初始化种群

一般的混沌序列具有非线性、遍历性、普适性和随机性等特点,经过文献[14]验证,混沌序列在种群初始化、选择、交叉和变异等操作上的效果比随机初始化种群好。为了能够丰富种群的多样性,利用随机初始种群和混沌映射相结合的办法,采用混沌映射初始化种群,Tent映射在数学表达式上为分段的线性映射,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。其数学表达如式(5)所示。

$$f(x_n) = \begin{cases} \frac{x_n}{\alpha}, & x_n \in [0, \alpha] \\ \frac{1-x_n}{1-\alpha}, & x_n \in [\alpha, 1] \end{cases} \quad (5)$$

其中, α 取 0~1 之间是随机数,一般取 0.5。

2.2 反向学习策略

反向学习的概念是 Tizhoosh^[15] 在 2005 年提出的以改善算法陷入局部最优的策略。反向学习的机制是利用现有可行解寻找到对应的反向解,经过反向机制评估并保存较好的解,这一过程考虑到了最优解与最差解,以便扩大搜索范围,防止算法陷入局部极值,以提高全局探索能力。采用反向学习策略,如式(6)~(9)所示。

$$\vec{C}_i = lb + X_i \cdot (ub - lb) \quad (6)$$

$$\vec{C}_i^r = rand \cdot (\min_number + \max_number) - \vec{C}_i \quad (7)$$

$$\min_number = \min(\vec{C}_i) \quad (8)$$

$$\max_number = \max(\vec{C}_i) \quad (9)$$

$$\vec{C}^p = [\vec{C}_i, \vec{C}_i^r] \quad (9)$$

其中, \vec{C}_i 是种群初始位置向量, X_i 是 0~1 的随机变量,设置种群规模 M , 其中 $i = 1, 2, \dots, M$, lb 表示搜索空间的下界, ub 表示搜索空间的上界。 \vec{C}_i^r 是初始解对应的反向解,式(6)是对初始解求反解,式(7)表示的是找到种群初始位置的最小值,式(8)是找到种群初始位置的最大值。式(9)是将 \vec{C}_i 与 \vec{C}_i^r 两种解合并组成新的群。

2.3 改进的平衡算法

平衡优化算法是 Faramarzia 在 2020 年提出的一种新型基于物理的元启发式算法^[16],平衡优化算法的寻优模型是帮助节点寻找平衡状态,根据平衡候选解进行更新,最终达到平衡状态。

1) 均衡池

通过混沌与随机种群初始化之后,节点缺少到达平衡状态的依据,在此基础上,可以计算节点的初始化适应度值,得到 4 个候选解 $\vec{C}_1, \vec{C}_2, \vec{C}_3, \vec{C}_4$, 同时根据 4 个候选解得到初始平均候选解 \vec{C}_{ave} , 将 5 个候选解依次放到均衡池 \vec{C}_e

里,如式(10)所示。之后在均衡池里随机选择一个候选解如式(11)所示,当作判断平衡状态的依据,将随机的候选解融入到浓度更新过程。

$$\vec{C}_e = \{\vec{C}_1, \vec{C}_2, \vec{C}_3, \vec{C}_4, \vec{C}_{ave}\} \quad (10)$$

$$\vec{C}_{eq} = rand(\vec{C}_e) \quad (11)$$

其中, \vec{C}_{eq} 的值为随机选择均衡池中的 5 个候选解。

2) 双曲正切高斯策略

为了进一步增强混合算法的全局与局部搜索能力,提出了一种双曲正切高斯策略^[17]。该策略结合了黄金分割数与高斯分布,把种群的迭代信息嵌入到双曲正切函数里,让种群更符合一般规律,增强算法的寻优能力,其改进公式如式(12)~(14)所示。

$$gn = \frac{\sqrt{5}-1}{2} \quad (12)$$

$$th = \tanh\left(\pi \frac{(t_{max} - iter)}{t_{max}}\right) \quad (13)$$

$$f = normpdf(gn, th) \quad (14)$$

其中, $normpdf(gn, th)$ 是高斯分布函数, gn 表示均值,同时 gn 也是黄金分割数,融入到高斯分布中,使高斯分布具有黄金分割数的优势; th 表示方差,将迭代次数与最大迭代次数融入双曲正切函数,可以动态调整高斯分布,并且具有自学习进化规律。最后作用于平均候选解,平均候选解如式(15)所示。

$$\vec{C}_{ave}^r = \vec{C}_{ave} \cdot normpdf(gn, th) \quad (15)$$

3) 改进非线性收敛因子

在平衡优化算法中控制因子 $a_1 = 2, a_2 = 1$, 固定 a_1 和 a_2 值不能自适应调整迭代次数,进而影响探索和开发能力,最终会导致寻优效果差的问题。文献[18]中,提到平衡器优化算法利用动态正余弦因子对 WSN 进行覆盖优化,因此将正弦因子 a_1 融入到控制因子 t_0 和指数项 \vec{U} 之中,将余弦因子 a_2 融入到收敛因子当中,如式(16)所示。

$$a = 2\cos\left(\frac{u^2}{t_{max}} \cdot \frac{\pi}{2}\right), u = \left(t - a_2 \frac{t}{t_{max}}\right) \quad (16)$$

其中,正余弦因子 a_1 和 a_2 分别如式(17)和(18)所示。

$$a_1 = 0.5\sin\left(\left(1 - \frac{iter}{t_{max}}\right)^4 \cdot \frac{\pi}{4}\right) \quad (17)$$

$$a_2 = 0.5\cos\left(\left(1 - \frac{iter}{t_{max}}\right)^4 \cdot \frac{\pi}{4}\right) \quad (18)$$

正弦因子 a_1 大约从 0.35 非线性递减并无限趋近于 0, 余弦因子 a_2 从 0.35 非线性递增到 0.5。将正弦因子 a_1 融入到 t_0 和 \vec{U} 之中,可以让算法寻找到最优节点;将余弦因子 a_2 融入到收敛因子当中,使得寻找到的最优节点在三维空间得到深度开发。非线性控制参数 a 从 2 线性递减到 0, 前期递减速度较慢,可以增加全局搜索能力,后期递减速度较快,能够改善局部搜索。

4) 浓度更新方程

浓度更新方程采用文献[19]的方式,节点从当前位置

向三维空间中任一位置进行寻优的浓度更新方程如式(19)所示。

$$\vec{C} = \vec{C}_{eq} + (\vec{C} - \vec{C}_{eq})\vec{U} + \frac{\vec{F}}{\lambda V}(1 - \vec{U}), \lambda \in [0, 1] \quad (19)$$

其中, \vec{C} 是当前节点, \vec{F} 表示生成率, 作用是提升开发能力, V 表示单位体积, $\vec{\lambda}$ 是 0~1 的随机向量, \vec{U} 是指数项, 主要用来平衡探索与开发, 指数项表达式如 (20) 所示。

$$\vec{U} = a_1 \text{sign}(\text{rand} - 0.5) (e^{-\vec{\lambda}t} - 1) \quad (20)$$

$$t = \left(1 - \frac{\text{iter}}{t_{\max}}\right)^{\frac{a_2 \text{iter}}{t_{\max}}} \quad (21)$$

由式(20)可知, a_1 是动态正弦因子, 常用来加速勘探和开发, $\text{sign}(\text{rand} - 0.5)$ 为符号函数项, 用来控制勘探与开发的方向, t 是有关迭代次数与最大迭代次数的线性递减的非线性因子, a_2 是控制开发能力的动态余弦因子。 \vec{F} 表示生成率, 其表达式如式(22)所示。

$$\vec{F} = \vec{F}_0 e^{-\vec{\lambda}t} \quad (22)$$

生成率 \vec{F}_0 的作用是在降低搜索速度的同时提升算法的勘探开发能力, 它的表达式如式(23)所示。

$$\vec{F}_0 = \frac{1}{\lambda} \ln[-a_1 \text{sign}(\text{rand} - 0.5) (1 - e^{-\vec{\lambda}t})] + t \quad (23)$$

$$\vec{F}_0 = \vec{GCP}(\vec{C}_{eq} - \vec{\lambda}\vec{C}) \quad (24)$$

$$\vec{GCP} = \begin{cases} 0, & \text{rand}2 < GP \\ 0.5\text{rand}1, & \text{rand}2 \geq GP \end{cases} \quad (25)$$

\vec{F}_0 主要根据 \vec{GCP} 的状态来控制节点的, GP 决定了节点的状态。 $\text{rand}1, \text{rand}2$ 都是 0~1 的随机数。

2.4 改进灰狼位置方程

灰狼算法具有控制参数少, 易于实现等优势广泛用于函数优化、智能控制等新兴领域^[20]。该算法 (grey wolf optimizer, GWO) 由 Mirjalili 等^[21] 根据灰狼种群等级制度与狩猎机制于 2014 年提出的一种新型群体智能优化算法。在自然界中, 灰狼等级分为 α 狼、 β 狼和 δ 狼和 ω 狼 4 个等级。在 d 维搜索空间中, 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 $G_I = G(G_1^I, G_2^I, G_3^I, \dots, G_d^I)$ 。

首先描述灰狼逐渐包围猎物的数学模型, 对于第 I 只狼如式(26)所示。

$$G_I^d(t+1) = G_p^d(t) - A_I^d | C_I^d G_p^d(t) - G_I^d(t) | \quad (26)$$

其中, $G_p = G(G_p^1, G_p^2, G_p^3, \dots, G_p^d)$ 描述了猎物的位置, t 为当前迭代次数, $A_I^d | C_I^d G_p^d(t) - G_I^d(t) |$ 为包围步长。其中 A_I^d 与 C_I^d 分别表示为:

$$A_I^d = 2a \cdot r_1 - a, r_1 \in [0, 1] \quad (27)$$

$$C_I^d = 2 \cdot r_2, r_2 \in [0, 1] \quad (28)$$

$$a_3 = 2 - 2t/t_{\max} \quad (29)$$

A_I^d 的值受控制参数影响, 也呈线性递减, 其中 A_I^d 是 $-a \sim a$ 的随机值。式(27)与(28)中 r_1 和 r_2 为 0~1 区间

的随机数, 其中收敛因子 a_3 , 从 2~0 线性递减, 受控于当前迭代次数 t, t_{\max} 为最大迭代次数。

由于 GWO 算法后期搜索能力差, 容易早熟等缺点, 提出了一种分段的灰狼位置更新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:

$$\begin{cases} x_{d1}^{t-1}(t+1) = G_a^d(t) - D_{I,a}^d(t+1), \\ x_{d1}^{t-1}(t+1) = D_{I,a}^d(t+1) + 2a \cdot \text{rand} \cdot (G_a^d(t) - G_I^d(t)), \end{cases} \quad (30)$$

其中, g 是维数 $[1, 2, 3, \dots, \text{dim}]$ 区间上的随机数, h 是种群个数 $[1, 2, 3, \dots, \text{sizepop}]$ 区间上的随机数。对于 β 和 δ 狼, 位置更新方程为:

$$\begin{cases} x_{d2}^{t-1}(t+1) = G_\beta^d(t) - D_{I,\beta}^d(t+1), & \text{rand} > 0.67 \\ x_{d2}^{t-1}(t+1) = \frac{(D_{I,a}^d(t+1) + D_{I,\beta}^d(t+1))}{2}, & \text{rand} \leq 0.67 \end{cases} \quad (31)$$

$$\begin{cases} x_{d3}^{t-1}(t+1) = G_\delta^d(t) - D_{I,\delta}^d(t+1), & \text{rand} > 0.33 \\ x_{d3}^{t-1}(t+1) = \frac{(D_{I,a}^d(t+1) + D_{I,\beta}^d(t+1) + D_{I,\delta}^d(t+1))}{3}, & \text{rand} \leq 0.33 \end{cases} \quad (32)$$

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 狼动态加权变异, 变异方程系数如式 (33) 所示。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, 位置更新方程如式(34)所示。

$$\begin{cases} \omega_\alpha = \frac{D_{I,\alpha}^d(t+1)}{D_{I,\alpha}^d(t+1) + D_{I,\beta}^d(t+1) + D_{I,\delta}^d(t+1)} \\ \omega_\beta = \frac{D_{I,\beta}^d(t+1)}{D_{I,\alpha}^d(t+1) + D_{I,\beta}^d(t+1) + D_{I,\delta}^d(t+1)} \\ \omega_\delta = \frac{D_{I,\delta}^d(t+1)}{D_{I,\alpha}^d(t+1) + D_{I,\beta}^d(t+1) + D_{I,\delta}^d(t+1)} \end{cases} \quad (33)$$

$$x_{d4}^{t+1}(t+1) = \frac{W_\alpha \cdot x_{d1}^{t+1} + W_\beta \cdot x_{d2}^{t+1} + W_\delta \cdot x_{d3}^{t+1}}{3} \quad (34)$$

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。其中 α 狼、 β 狼和 δ 狼的包围步长为:

$$\begin{cases} D_{I,\alpha}^d(t+1) = A_{I,1}^d | C_I^d G_\alpha^d(t) - G_I^d(t) | \\ D_{I,\beta}^d(t+1) = A_{I,2}^d | C_I^d G_\beta^d(t) - G_I^d(t) | \\ D_{I,\delta}^d(t+1) = A_{I,3}^d | C_I^d G_\delta^d(t) - G_I^d(t) | \end{cases} \quad (35)$$

3 EGWOE 算法的 WSN 三维覆盖优化步骤

虽然在监测区域采用 Tent 混沌映射部署节点之后增加了种群多样性, 但仍会存在覆盖冗余。为了解决这个问题, 以覆盖率为适应度函数, 利用 EGWOE 算法确定覆盖率最优的节点部署方案。

EGWOE 算法的 WSN 三维覆盖优化步骤如下:

步骤 1) 初始化网络参数及基本参数, 监测区域边长 L 、节点个数 N 、感知半径 R_s 、通信半径 R_c 、空间维数

dim 、最大迭代次数 t_{max} , 上界 $ub = L$, 下界 $lb = 0$ 。

步骤 2) 准备目标函数, 离散化三维区域内的点, 准备适应度函数, 即覆盖率, 适应度函数是描述 WSN 覆盖率的重要步骤。

步骤 3) 初始化覆盖率曲线和适应度函数。

步骤 4) 利用 Tent 混沌映射式(5)初始化种群, 增加种群的多样性。

步骤 5) 根据 Tent 混沌映射得到的初始化种群位置向量, 找到初始种群位置的最小值和最大值, 由反向学习策略式(6)~(9)计算每个初始解对应的反向解, 将混沌映射的初始解与反向学习的反向解组合成新的种群位置向量, 得到初始化部署图。

步骤 6) 根据混沌映射的初始解与反向解的组合求取适应度函数, 之后将适应度函数升序排列, 取出最优的解得到新的初始种群。

步骤 7) 确定正余弦因子及收敛因子。

步骤 8) 将双曲正弦高斯策略应用于均衡池, 如式(12)~(15)所示。

步骤 9) 根据式(19)~(25)浓度更新, 取 $GP = 0.5$ 。

步骤 10) 保存种群向量和适应度函数。

步骤 11) 将保存的种群向量和适应度函数应用到改进的灰狼位置更新方程中, 以提高算法的收敛速度与精度。

步骤 12) 判断是否达到最大迭代次数, 没有达到返回步骤 6)。达到最大迭代次数, 跳出循环, 记录最优覆盖率, 画出覆盖率进化曲线, 最后得到优化部署图。

4 EGWOEO 算法性能测试

4.1 仿真参数设置

为了检验 EGWOEO 算法的性能, 在基于两种单峰函数和两种多峰函数的标准下进行性能测试, 基准测试函数的取值范围、最优解 f_{min} 及维度如表 1 所示。为保证实验的准确性, 在同一运行环境下进行测试, 设置相同参数, 种群数量一致为 30, 各算法独立运行 30 次, 迭代次数为 500 次, 比较多种灰狼算法。

表 1 测试函数

函数名	取值范围	f_{min}	维度
Sphere	$[-100, 100]$	0	30
Schwefel 2.21	$[-100, 100]$	0	30
Rastrigin	$[-5.12, 5.12]$	0	30
Griewank	$[-600, 600]$	0	30

4.2 收敛性分析

测试函数收敛曲线可以直观表示各算法的收敛精度与速度, 同时可以看出算法跳出局部空间的能力。选取 GWO 算法、文献[22]的 PSOGWO(grey wolf optimization

algorithm based on particle swarm optimization, PSOGWO) 算法和文献[23]的 LGWO(levy grey wolf algorithm, LGWO) 算法对比, 分析 GWO、PSOGWO、LGWO 和 EGWOEO 算法的覆盖性能。

如图 1(a)~(d)所示是 4 个基准函数的箱线图, 4 个基准函数中 EGWOEO 的解都接近最优解 0, 与理论最优值接近, 拥有更高的寻优精度, 4 种算法在 4 个基准函数上均存在特别大或者特别小的异常解, 且异常值都不太集中, 说明这些异常值是普遍存在的, 对算法影响不大。GWO 和 LGWO 算法在 F2 和 F3 上的结果, 虽然存在接近理论的数值 0, 但是不够集中于最优解。对于 PSOGWO 算法来说, 它的解都接近最优解 0, 但是它的异常值也不够集中。整体来看 EGWOEO 算法的寻优精度更高。

箱线图的高度可以判断算法的稳定性, 图 1(a)和(d)中 4 种算法的箱线图高度几乎一样, 即 4 种灰狼算法都拥有较低的波动性和较高的稳定性; 图 1(b)和(c)中 EGWOEO 和 PSOGWO 算法的高度几乎一致, 而 GWO 和 LGWO 算法的箱线图明显高于 EGWOEO 和 PSOGWO 算法, 所以在基准函数 F2 和 F3 上, EGWOEO 和 PSOGWO 算法具有更高的稳定性。

4 个基准函数收敛曲线如图 2(a)~(d)所示, 收敛曲线图中横轴表示迭代次数, 纵轴表示适应度值。从 4 种收敛曲线结果可知, EGWOEO 算法收敛速度较其他灰狼算法更快, 适应度值更低, 即寻优精度高。在如图 2(a)中, 迭代次数约为 200 次时, EGWOEO 算法的精度较 GWO 与 PSOGWO 算法高约 300 个数量级, 较 LGWO 算法高大约 275 个数量级; 图 2(b)中, 当迭代次数为 300 次时, EGWOEO 算法的收敛精度较其他 3 种算法高约 200 个数量级; 在图 2(c)和(d)中, EGWOEO 算法最先出现拐点, 说明该算法求解速度更快。综合判断 EGWOEO 不论是在寻优精度、收敛速度还是稳定性都具有更好的性能。

4.3 数值优化结果分析

由表 2 可知, 无论是单峰函数还是多峰函数, EGWOEO 算法相比其他灰狼算法有较大提升, 其标准差和均值都更接近理论最优解 0, 表明 EGWOEO 算法较强的稳定性和鲁棒性。反观 PSOGWO 算法, 以 F4 为例, PSOGWO 算法的均值为 154.470 0, 标准差为 191.143 6, 远远偏离最优解值 0, 虽然在其他 3 个函数上的均值和标准差相比 F4 来说偏离较小, 但和其他 3 种灰狼算法相比, 稍显逊色。数值优化结果仅次于 EGWOEO 算法的是 LGWO 算法, 其次是 GWO 算法。

从运行时间来看, GWO 算法的运行时间最短, 其次是 PSOGWO 算法与 EGWOEO 算法, 最后是 LGWO 算法, 虽然 EGWOEO 算法运行时间稍长, 但从 4 种运行时间结果来看, 大致在 1.3 s 附近, 相比于 EGWOEO 算法的收敛精度与速度的提升来说, 运行时间稍长也是可以接受的。

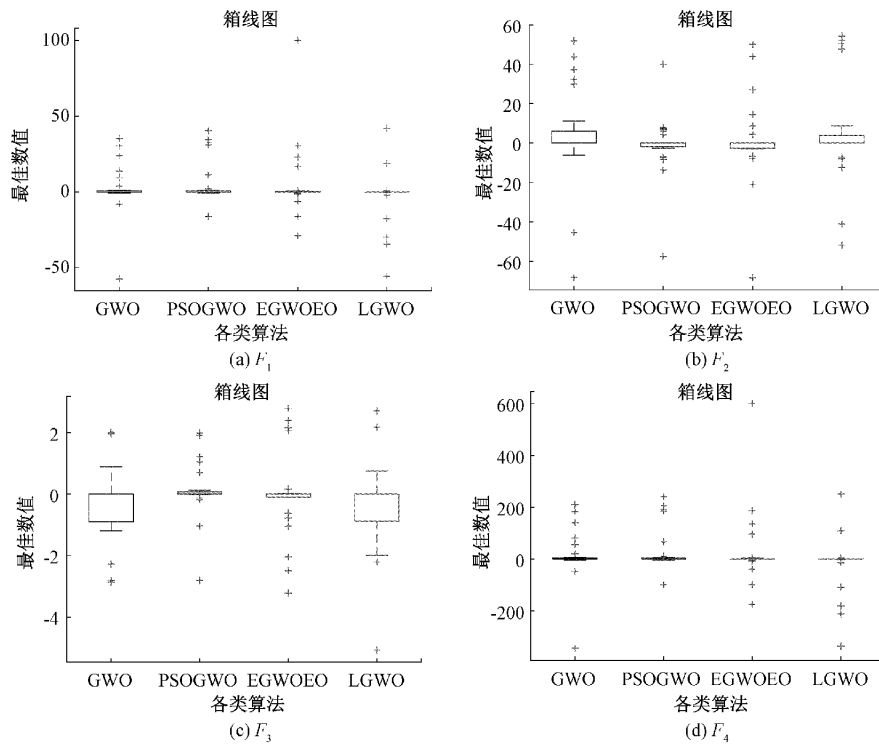


图 1 基准测试函数箱线图

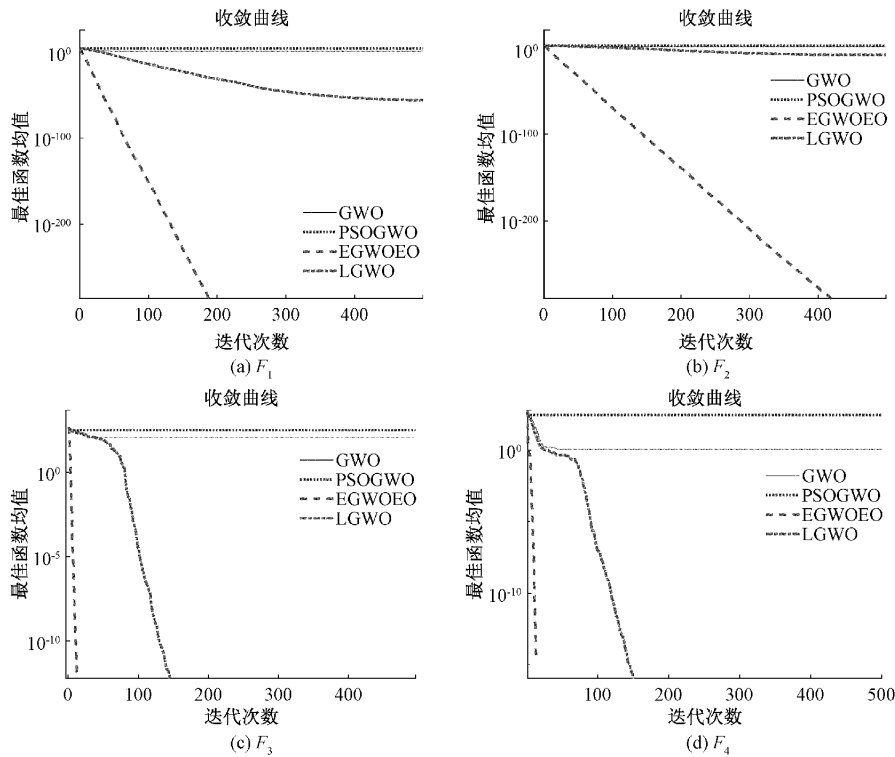


图 2 基准测试函数收敛曲线

表2 基准函数数值优化结果

函数	算法	均值	标准差	时间
F_1	GWO	0.432 3	0.561 3	0.095 146
	PSOGWO	25.741 7	31.834 4	0.114 227
	EGWOEO	$2.137 8 \times 10^{-164}$	0	1.327 941
	LGWO	$8.826 7 \times 10^{-30}$	$1.803 5 \times 10^{-29}$	3.320 948
F_2	GWO	5.103 6	5.805 2	0.097 754
	PSOGWO	33.074 3	38.264 2	0.125 269
	EGWOEO	0	0	1.452 432
	LGWO	$3.890 2 \times 10^{-19}$	$4.034 3 \times 10^{-19}$	3.301 138
F_3	GWO	0.816 9	1.112 3	0.107 658
	PSOGWO	1.662 6	2.005 6	0.121 284
	EGWOEO	$5.909 4 \times 10^{-11}$	$2.411 6 \times 10^{-9}$	1.308 903
	LGWO	$4.170 6 \times 10^{-10}$	$3.551 6 \times 10^{-9}$	3.648 788
F_4	GWO	2.594 1	3.368 0	0.121 474
	PSOGWO	154.470 0	191.143 6	0.135 327
	EGWOEO	$1.673 0 \times 10^{-11}$	$8.895 4 \times 10^{-9}$	1.337 475
	LGWO	$1.215 1 \times 10^{-10}$	$1.330 2 \times 10^{-8}$	4.450 986

5 EGWOEO算法的WSN三维覆盖优化仿真实验及分析

5.1 参数设置

为了检验改进灰狼算法的WSN覆盖性能,进行了仿真实验,仿真实验参数如表3所示。WSN覆盖性能都是在此参数基础上进行的,确保了仿真结果的准确性。仿真结果都是在实验20次的基础上得到的。仿真空间为密闭的三维正方形空间,在此空间中不考虑有障碍物、水文地形和其它外界影响因素,选取GWO算法、PSOGWO算法和LGWO算法,并将这3种算法拓展到三维空间,对比分析GWO、PSOGWO、LGWO和EGWOEO算法的覆盖性能。实验环境采用Windows 10家庭版64位操作系统,英特尔Intel(R) Core(TM) i5-10500U 3.10 GHz和8G内存的PC,编程环境为MATLAB R2020b。

表3 仿真参数设置

符号	参数	取值
n	目标区域	60 m×60 m×60 m
t_{\max}	最大迭代次数	500
N	传感器节点个数	70
M	种群规模	50
R_s	节点感知半径/m	10
R_c	通信半径	20
dim	空间维度	3
ub	上界	60
lb	下界	0

5.2 三维覆盖优化仿真

统一设置如5.1节中的仿真参数,对GWO、PSOGWO、LGWO和EGWOEO算法在WSN三维覆盖情况做了仿真实验,其中三维覆盖初始部署如图3所示,采用Tent映射初始化之后的初始覆盖率为69.548%,观察三维初始部署图可知,初始覆盖率效果较差,并且节点分布不均,导致节点重合,网络利用率低下。




图3 三维覆盖初始部署

如图4~6所示,是3种对比灰狼算法的无线传感网络三维覆盖的优化结果图,GWO、PSOGWO和LGWO覆盖率分别为74.085%、71.821%和71.106%,相比初始部署覆盖率分别提升了4.537%、2.273%和1.558%。虽然3种对比算法的覆盖率和节点均匀性比初始部署效果有所提升,但依旧存在节点不均,覆盖率低的问题。

如图7是EGWOEO算法的覆盖优化部署图,其覆盖




图 4 GWO 三维覆盖优化




图 7 EGWOEO 三维覆盖优化




图 5 PSOGWO 三维覆盖优化




图 6 LGWO 三维覆盖优化

率已经达到了 84.046%，覆盖率相比初始覆盖率提高了 14.588%。在同一实验条件下，EGWOEO 算法相比 GWO、PSOGWO、LGWO 算法的覆盖率增量分别为 9.961%、12.225%和 12.94%。对比其他 3 种灰狼算法，EGWOEO 算法节点分布更加均匀，节点的利用率也最大。仿真结果说明均衡池的存在让算法更符合种群进化规律，保证了节点的均匀性。

如图 8 所示是 4 种灰狼算法的覆盖率进化曲线，在规

定迭代次数为 500 的条件下，4 种灰狼算法的覆盖率随着迭代次数的增加而增加，LGWO 算法的覆盖率增长最慢，且在迭代 380 次左右收敛；其次是 PSOGWO 算法，大约在迭代 120 次左右达到收敛条件；之后是 GWO 算法，迭代次数大约为 475 次左右收敛；而改进的 EGWOEO 算法在迭代前期覆盖率增长较快，后期增长率依旧高于其他两种算法，在达到设置的最大迭代次数时，依旧没有收敛，说明该算法的有效性。相较于初始覆盖率，覆盖率增量最大的是 EGWOEO 算法，其次是 GWO 算法，之后是 PSOGWO 算法，最后是 LGWO 算法。对于 EGWOEO 算法来说，由于前期增加了混沌映射初始化种群，增加了种群多样性；反向学习策略利用反向解增加了全局最优解概率，使迭代前期覆盖率显著提升。

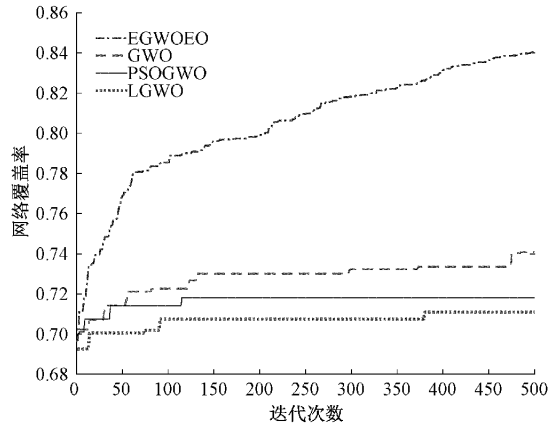


图 8 覆盖率进化曲线对比图

在无线传感网络中，节点数量对监测区域的覆盖率有着不同的影响。设置不同节点个数，观察不同节点个数对覆盖率的影响，4 种灰狼算法在各种节点下的覆盖率如表 4 所示(括号内为节点个数)。4 种灰狼算法随着节点个数的增加，覆盖率也相应增加。但 EGWOEO 算法在同一节点个数下的覆盖率较其它灰狼算法的覆盖率增量高。EGWOEO 算法覆盖率相比 GWO、PSOGWO 和 LGWO 算法的平均增量分别为 11.023%、10.662%和 12.401%，

进一步验证了EGWOEO算法的有效性。

表4 覆盖率与节点关系对比

算法	覆盖率(50)	覆盖率(55)	覆盖率(60)	覆盖率(65)
初始部署	0.578 00	0.610 24	0.646 98	0.672 16
GWO	0.636 41	0.642 81	0.661 85	0.718 84
PSOGWO	0.618 99	0.665 02	0.682 27	0.706 94
LGWO	0.596 38	0.634 74	0.664 22	0.690 36
EGWOEO	0.693 38	0.760 05	0.791 14	0.846 70
算法	覆盖率(70)	覆盖率(75)	覆盖率(80)	覆盖率(85)
初始部署	0.695 48	0.730 21	0.733 22	0.763 23
GWO	0.740 85	0.753 73	0.767 84	0.794 85
PSOGWO	0.718 21	0.769 97	0.786 09	0.798 55
LGWO	0.711 06	0.752 36	0.763 94	0.793 91
EGWOEO	0.840 46	0.875 7	0.882 73	0.908 85

6 结 论

对于三维无线传感网络出现的节点分布不均和覆盖率低的问题,提出了一种三维无线传感网络EGWOEO覆盖优化算法。其中混沌映射与反向学习策略本质上都增加种群的多样性;双曲正切高斯策略加强算法寻优能力;正余弦收敛因子协调了算法的开发和探索能力;改进灰狼位置方程提高算法收敛速度与精度。在4种基准函数的基础上对EGWOEO算法的收敛性与数值优化结果进行分析,验证该算法具有较强的稳定性和鲁棒性。将改进的算法应用到无线传感网络覆盖上,与GWO、PSOGWO和LGWO算法比较,EGWOEO算法大幅提高了三维空间的无线传感网络覆盖率,改善了节点分布不均现象。该算法在改善节点均匀性问题上,只有在不考虑障碍物和其它外界因素的情况下适用,有一定的局限性,以后的工作中,将围绕三维节点的均匀性、连通性和能耗进行研究,还可以考虑三维空间有障碍物情况下的无线传感网络覆盖优化问题。

参考文献

- [1] 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.
- [2] 黄晓璐, 欧峰. 担任确保覆盖和连通性的WSN寿命最大化[J]. 电子测量与仪器学报, 2019, 33(1): 61-68.
- [3] KHALAF O I, ABDULSAHIB G M, SABBAR B M. Optimization of wireless sensor network coverage using the bee algorithm[J]. Journal of Information Science and Engineering, 2020, 36(2): 377-386.
- [4] 张伟, 赵晓侠. 一种长寿命和高覆盖可靠性的WSN实现[J]. 国外电子测量技术, 2022, 41(3): 145-151.
- [5] QI X, LI Z, CHEN C. A wireless sensor node

deployment scheme based on embedded virtual force resampling particle swarm optimization algorithm[J]. Applied Intelligence, 2022, 52(7): 7420-7441.

- [6] 吴帅, 孙力娟, 肖甫, 等. 面向三维的无线传感器网络覆盖增强算法[J]. 计算机研究与发展, 2011, 48(S2): 106-110.
- [7] 孙爱晶, 王磊, 朱鑫鑫. 基于融合算法的三维无线传感器网络覆盖优化[J]. 传感器与微系统, 2021, 40(11): 146-149.
- [8] PRIYADARSHI R, GUPTA B. Area coverage optimization in three-dimensional wireless sensor network [J]. Wireless Personal Communications, 2021, 117(2): 843-865.
- [9] 刘惠, 柴志杰, 杜军朝, 等. 基于组合虚拟力的传感器网络三维空间重部署算法研究[J]. 自动化学报, 2011, 37(6): 713-723.
- [10] 郝占军, 曲南江, 党小超. 复杂环境下一种多移动节点的WSN三维覆盖算法[J]. 计算机工程, 2019, 45(2): 114-121, 128.
- [11] LIL B, CHEN Y, WAN J. Data collection algorithm of a 3D wireless sensor network that weighs node coverage rate and lifetime[J]. IEEE Access, 2020, 8: 214978-214991.
- [12] 党小超, 邵晨光, 郝占军. 半径可调的无线传感器网络三维覆盖算法[J]. 计算机应用, 2018, 38(9): 2581-2586, 2615.
- [13] 周挺. 全向传感器网络中基于虚拟力的三维覆盖增强算法[J]. 内蒙古师范大学学报(自然科学汉文版), 2017, 46(4): 566-570.
- [14] LIU J, ZHONG M, LIU B, et al. Design of three-dimensional dynamic integer tent map and its image encryption algorithm [J]. Multimedia Tools and Applications, 2021(3): 1-18.
- [15] TIZHOOSH H R. Opposition-based learning: A new scheme for machine intelligence [C]. International Conference on International Conference on Computational Intelligence for Modelling, Control & Automation, IEEE, 2005: 695-701.
- [16] AFSHIN F, MOHAMMAD H J, BRENT S, et al. Equilibrium optimizer: A novel optimization algorithm[J]. Knowledge-Based Systems, 2020, 191(C), DOI: 10.1016/j.knsys.2019.105190.
- [17] 李守玉, 何庆, 陈俊. 双曲正切高斯与两阶段反向学习平衡优化算法[J/OL]. 小型微型计算机系统: 1-9 [2022-04-19]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20220223.1115.004.html>.
- [18] 刘丽娟, 刘定一, 刘婷婷. 改进的正余弦优化算法在WSN覆盖中的应用[J]. 数学的实践与认识, 2021,

- 51(11): 129-137.
- [19] 李守玉, 何庆, 陈俊. 改进平衡优化器算法的 WSN 覆盖优化[J/OL]. 计算机应用研究: 1-7[2022-04-15]. DOI:10.19734/j.issn.1001-3695.2021.09.0403.
- [20] ZHANG Y, CAO L, YUE Y. 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.
- [21] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [22] 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.
- [23] 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.

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、信号与信息处理、无线传感器网络等。

曾蝶(通信作者), 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

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。