

基于多策略融合改进蛇优化算法的 WSN 覆盖优化研究

李胜锋, 田彦山, 马旭, 张芳琴, 杨金米, 马甜甜, 罗晓丽

(宁夏师范大学数学与计算机科学学院, 宁夏 固原 756099)

摘要: 为优化无线传感器网络 (wireless sensor network, WSN) 节点随机部署所导致的覆盖空洞、分布不均, 以及能效低等问题, 提出了一种多策略融合改进蛇优化 (multi-strategy snake optimizer, MSSO) 算法。首先, 采用 Tent 混沌映射与改进对立学习策略生成高质量初始种群, 以提升初始解的质量; 其次, 引入随机-精英交替引导机制, 用于平衡并增强算法的全局搜索能力; 再次, 在开发阶段进一步融合自适应量子竞争纠缠与遗传表观调控机制, 旨在增强种群多样性并加速收敛; 最后, 采用动态适应度排名策略, 自适应调整种群选择压力。仿真实验结果表明, 与 3 类改进算法相比, MSSO 算法在网络覆盖率与节点分布均匀性方面均表现出更优性能, 为解决 WSN 覆盖优化问题提供了一种有效的解决方案。

关键词: 无线传感器网络; 覆盖优化; 蛇优化算法; Tent 混沌映射; 精英领导; 自适应策略

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.2096-3750.WLW25156

WSN coverage optimization based on an improved snake optimizer with multi-strategy integration

Li Shengfeng, Tian Yanshan, Ma Xu, Zhang Fangqin, Yang Jinmi, Ma Tiantian, Luo Xiaoli

School of Mathematics and Computer Science, Ningxia Normal University, Guyuan 756099, China

Abstract: To address the issues of coverage holes, uneven node distribution, and low energy efficiency caused by random node deployment in wireless sensor networks (WSN), a multi-strategy snake optimizer (MSSO) algorithm was proposed. Firstly, Tent chaotic mapping and an improved opposition-based learning strategy were employed to generate a high-quality initial population. Secondly, a random-elite alternating guidance mechanism was designed to enhance the exploration capability of the algorithm. Subsequently, adaptive quantum competitive entanglement and genetic epigenetic regulation mechanisms were introduced during the exploitation phase to increase population diversity and improve convergence. Finally, a dynamic fitness ranking strategy was adapted to adaptively adjust the selection pressure. Simulation results demonstrated that, when compared with three types of improved algorithms, MSSO exhibited superior performance in terms of both network coverage rate and node distribution uniformity, thereby providing an effective solution for WSN coverage optimization.

Key words: wireless sensor network, coverage optimization, snake optimization algorithm, Tent chaotic mapping, elite guidance, adaptive strategy

收稿日期: 2025-10-12; 修回日期: 2026-09-10

通信作者: 田彦山, tianysh@nxnu.edu.cn

基金项目: 国家自然科学基金地区科学基金资助项目 (No. 62566048, No. 62262054), 宁夏回族自治区重点研发计划项目 (No. 2023BEG02072), 宁夏回族自治区自然科学基金资助项目 (No. 2025AAC030615)

Foundation Items: Regional Science Foundation Project of The National Natural Science Foundation of China (No. 62566048, No. 62262054), The Key Research and Development Program of Ningxia Hui Autonomous Region (No. 2023BEG02072), The Natural Science Foundation of Ningxia Hui Autonomous Region (No. 2025AAC030615)

0 引言

无线传感器网络 (wireless sensor network, WSN) 是由大量分布式微型传感器节点构成的无线自组织网络体系, 能够对特定区域的环境条件与物理现象进行协同感知、采集与处理^[1]。WSN 凭借其灵活性与移动性, 在环境监测^[2]、军事侦察^[3]、智能家居^[4]乃至地质灾害预警^[5]等人类难以到达或无法干预的复杂环境中展现出了巨大的应用价值。然而, 在实际部署中, 受恶劣环境、节点能耗受限等因素的影响, 精确的确定性部署往往难以实现, 因此, 随机部署成为常态。随机部署易导致节点分布不均、网络中出现覆盖空洞^[6]和冗余区域, 严重影响网络的整体服务质量 (quality of service, QoS) 与能量效率^[7]。因此, 如何对随机部署的节点位置进行优化, 以最少的节点资源实现最大化的有效覆盖, 已成为 WSN 领域的关键研究课题。

为应对这一挑战, 具备强全局搜索能力与高效性的元启发式算法被引入 WSN 节点覆盖优化研究中。现有研究先后将粒子群算法^[8]、鲸鱼优化算法^[9]和麻雀搜索算法^[10]等应用于该问题, 在提升网络覆盖率与均衡能耗方面取得了可观收益^[11]。具体来看, 王振东等^[12]融合双重反冲运动与互利学习策略, 显著改善了水下传感器网络的布局质量; 周恺卿等^[13]在布谷鸟搜索中采用分阶段更新与精英反向学习机制, 同样取得了明显覆盖增益。面对新兴蛇优化 (snake optimizer, SO) 算法, 程仁轩等^[14]结合精英反向学习与纵横交叉策略, 在扩展覆盖范围的同时增强了节点连通性; 李振等^[15]则从种群初始化及觅食交配行为层面重构算法, 虽获得了优异的覆盖表现, 但算法前期收敛速度仍有待提升。值得关注的是, 张勇等^[16]进一步整合 Circle 映射、自适应螺旋搜索与差分进化策略, 在优化覆盖性能的同时实现了降低能耗与延长网络生命周期的多目标平衡。上述研究进展表明, 混合改进策略能够有效改善 WSN 覆盖优化性能, 但多数算法在收敛速度与局部搜索精度之间仍面临权衡困境^[17]。由此可见, 在保持深度寻优能力的同时全面提升优化效率, 仍是该领域亟待突破的关键问题。

SO 算法^[18]是 2022 年提出的一种新型元启发式算法, 该算法模拟蛇类觅食与交配行为实现优化搜索, 且凭借独特的运行机制, 在多个领域展现出良好的应

用前景。然而, 将标准 SO 算法直接应用于 WSN 覆盖优化问题时, 仍表现出全局探索能力偏弱、迭代后期易陷入早熟收敛等内在局限, 尤其在前期搜索阶段收敛速度迟缓, 制约了算法的整体优化效能。

为解决传统 SO 算法应用于 WSN 节点部署时存在的上述问题, 本文提出了一种多策略融合的改进蛇优化 (multi-strategy snake optimizer, MSSO) 算法。针对原生 SO 算法在种群初始化、探索与开发等关键阶段的不足, MSSO 算法进行了系统增强, 核心创新内容主要包含 4 个方面: (1) 融合 Tent 混沌映射与改进对立学习策略, 构建兼具分布均匀性与区域针对性的高质量初始种群; (2) 设计随机一精英交替引导搜索机制, 实现全局与局部搜索能力的动态均衡; (3) 引入自适应量子竞争纠缠与遗传表观调控双重优化策略, 强化种群个体间的信息交互与协同迭代能力, 引导算法快速收敛至优质解区域; (4) 采用动态适应度排名机制, 自适应调节种群选择压力, 精准把控算法迭代寻优过程。借由上述机制, MSSO 算法可全面提升 SO 算法的优化精度与收敛效率, 为 WSN 覆盖优化问题提供一种更稳健、高效的解决方案。

1 模型描述

1.1 覆盖感知模型

WSN 覆盖模型用于评估其对感兴趣区域 (region of interest, RoI) 内目标事件的监测感知能力。传感器的传感范围、通信范围, 以及节点的移动能力是传感器节点实现有效覆盖的基础要素。借助节点可移动特性, WSN 能够动态调整节点布局, 从而协同优化覆盖性能与网络连通性。本文构建的 WSN 覆盖优化模型基于布尔感知模型^[19], 并以最大化区域覆盖率为优化目标。

在布尔感知模型中, 单个传感器对某一网点的感知行为被描述为一个二元事件。设网格点 i 的坐标为 $g_i=(x_i, y_i)$, 传感器节点的坐标为 $s_j=(x_j, y_j)$, 第 i 个网格中心点的坐标为 G_i , 第 j 个传感器的坐标为 S_j , 传感器的感知半径为 R , 传感器 j 对网格点 i 的感知概率 $P(G_i, S_j)$ 可表示为:

$$P(G_i, S_j) = \begin{cases} 1, & d(G_i, S_j) \leq R \\ 0, & d(G_i, S_j) > R \end{cases} \quad (1)$$

其中, $d(G_i, S_j)$ 为网格点 i 与传感器 j 之间的欧氏距离。 $d(G_i, S_j)$ 的数学表达式为:

$$d(G_i, S_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (2)$$

在假设各传感器节点可相互独立地感知事件的前提下，任一网格点 i 被整个WSN所覆盖的联合概率 $P_{\text{cov}}(G_i)$ 为：

$$P_{\text{cov}}(G_i) = 1 - \prod_{j=1}^N (1 - P(G_i, S_j)) \quad (3)$$

其中， N 表示传感器总个数。

设 M 为离散化的网格点总数，网络的整体覆盖率 C_R 定义为所有离散网格点被覆盖概率的算术平均值，该值等价于被有效覆盖的面积与监测区域总面积之比。覆盖率 C_R 是文本方法需要优化的目标函数，其数学表达式为：

$$C_R = \frac{\sum_{i=1}^M P_{\text{cov}}(G_i)}{M} \quad (4)$$

1.2 节点移动指派模型

针对WSN中节点随机部署后的位置优化问题，节点移动指派模型用于确定传感器从初始位置迁移至优化目标位置的最优分配方案。节点移动距离是影响网络部署效率的关键指标。本文构建的节点移动指派模型采用线性指派问题（linear assignment problem, LAP）框架^[20]，并以最小化总体迁移成本为优化目标。

在线性指派模型中，匹配关系由二元决策变量 x_{ij} 表征。设初始节点 i 的位置为 g_i ，目标位置 j 的位置为 q_j 。节点 i 迁移至目标位置 j 的成本 c_{ij} 即为两者间的欧几里得距离：

$$c_{ij} = \|g_i - q_j\| \quad (5)$$

所有这些成本构成了成本矩阵 C 。若节点 i 被指派至目标位置 j ，则 $x_{ij}=1$ ；反之， $x_{ij}=0$ 。该指派问题的数学模型可表示如下：

$$\begin{aligned} \min & \sum_{i=1}^n \sum_{j=1}^n c_{ij} \cdot x_{ij} \\ \text{st.} & \sum_{j=1}^n x_{ij} = 1, \quad \forall i \in \{1, \dots, n\} \\ & \sum_{i=1}^n x_{ij} = 1, \quad \forall j \in \{1, \dots, n\}, \\ & x_{ij} \in \{0, 1\}, \quad \forall i, j \in \{1, \dots, n\} \end{aligned} \quad (6)$$

2 改进蛇优化算法

2.1 Tent混沌映射与改进对立学习策略

种群初始化是元启发式算法的起始环节，初始

解的质量与空间分布状态对算法的全局搜索效率和最终寻优精度具有至关重要的影响。标准SO算法采用简单的随机方式生成初始种群，这种方式虽然操作简单，但其固有的随机性容易导致种群分布不均和多样性不足。具体而言，随机生成的个体可能堆于搜索空间的局部区域，形成大面积的“盲区”，这不仅降低了前期迭代的搜索效率，也增加了算法陷入局部最优、发生“早熟”收敛的风险。

为克服上述缺陷，MSSO算法首先采用Tent混沌映射^[21]，以增强种群的遍历性与均匀性。在此基础上，借鉴对立学习均衡优化器的思想^[22]，进一步提出一种新颖的改进对立学习策略。其中，Tent混沌映射的数学表达式为：

$$x_{k+1} = \begin{cases} \mu \cdot x_k, & x_k \leq 1/\mu \\ \mu \cdot (1 - x_k), & x_k > 1/\mu \end{cases} \quad (7)$$

$$X_c = X_l + (X_u - X_l) \cdot X_{\text{chaos}} \quad (8)$$

其中， μ 为Tent混沌序列的控制参数； x_k 、 x_{k+1} 分别为第 k 、 $k+1$ 次迭代生成的混沌序列值； X_c 为经混沌映射转换到搜索空间的个体位置， X_{chaos} 为Tent混沌序列； X_u 和 X_l 为空间的上下边界。

再进一步生成随机解、对立解和检测区域中心解，其表达式分别为：

$$X_r = X_l + r(0,1) \cdot (X_u - X_l) \quad (9)$$

$$X_o = X_l + X_u - X_r \quad (10)$$

$$X_q = (X_r + X_o)/2 \quad (11)$$

其中， r 为0~1的随机数； X_r 为搜索空间内生成的随机个体位置； X_o 为 X_r 对应的对立个体位置， X_q 为检测区域中心位置。

随后，将生成的 X_c 、 X_r 、 X_o 和 X_q 合并，构成一个统一的候选池。依据预设的适应度函数对统一候选池中的所有解进行评估和降序排列，并择优选取与种群规模等量的解，构成用于后续迭代的初始种群。最终，构建出一个多样性与质量兼备的高性能初始种群，为算法后续的全局搜索奠定坚实的基础，从而有效提升算法的整体收敛速度与寻优精度。

2.2 随机—精英交替引导的搜索机制

标准SO算法在全局探索阶段仅采用单一随机搜索策略，该模式虽然有助于保持搜索的广度，但缺乏有效迭代引导机制，容易造成搜索过程盲目性强、寻优效率低下的问题。为弥补这一缺陷，本文设计了一种随机—精英交替引导的搜索机制。该机

制受改进灰狼优化算法^[23]的启发,融合两种功能互补的搜索行为,以应对WSN覆盖优化中全局勘探与局部开发的双重迭代需求。随机个体与精英个体引导更新的数学表达式如下:

$$X_{\text{new},m(f),i,j} = X_{\text{rand},m(f),j} \pm c_2 \cdot A_{m(f)} \cdot (r \cdot (X_{\text{max}} - X_{\text{min}}) + X_{\text{min}}) \quad (12)$$

$$X_{\text{new},m(f),i,j} = X_{\text{rand},m(f),j} \pm c_2 \cdot A_{m(f)} \cdot (X_{\text{food},j} - X_{\text{rand},m(f),j}) \quad (13)$$

其中, c_2 为步长调节系数; $A_{m(f)}$ 为雌/雄个体的探索能力; X_{max} 和 X_{min} 分别为对应维度搜索空间的上界与下界。

具体而言,随机引导模式保留了标准SO算法的全域搜索能力,通过向随机个体学习维持种群多样性,能够增强算法逃离局部极值的能力,从而保障全局搜索的覆盖范围;精英引导模式则引入当前最优解信息,指引种群朝向高适应度优质解区域收敛,有效加速算法迭代收敛进程。两种搜索模式通过周期切换动态交替工作,使全局搜索在广度和深度之间取得平衡,显著提高了优质解区域的搜寻效率,为后续局部精细开采奠定了更坚实的基础。

2.3 融入自适应量子竞争纠缠扰动与遗传表观调控机制

2.3.1 自适应量子竞争纠缠扰动

标准SO算法在局部开发阶段的战斗模式中,个体位置更新依赖随机生成的固定步长,缺乏对种群收敛状态的自适应能力。这种机制存在明显局限:迭代后期,种群趋于收敛,固定步长易引起最优解附近震荡,难以实现精确收敛;迭代前期,步长若过小则会延缓收敛速度。为解决该问题,本文引入量子纠缠机制^[24],依据最优个体与种群平均适应度之间的差异,动态构造反映种群分布状态的纠缠因子,据此实时调节更新步长。当最优解显著优于种群平均水平时,增大步长,以加速逼近优质区域;当种群适应度差异较小时,则减小步长,以提升局部开采精度。该方法有效提升了SO算法在局部开发阶段的自适应能力,兼顾了收敛速度与最终解的质量。其数学表达式为:

$$X_{i,m(f)}(t+1) = X_{i,m(f)}(t) + c_3 \cdot E \cdot F_{m(f)} \cdot r \cdot (Q \cdot X_{\text{best},f(m)}(t) - X_{i,m(f)}(t)) \quad (14)$$

其中, $F_{m(f)}$ 为雄性(或雌性)的战斗能力; c_3 为战斗阶段的步长调节系数; t 为当前迭代次数; $X_{\text{best},m(f)}$

为雄性(或雌性)最优个体; $X_{i,m}$ 和 $X_{i,f}$ 分别表示第 i 个雄性和雌性个体; E 为动态扰动因子,其数学表达式为:

$$E = 1 + \beta \cdot (r(0,1) - 0.5) \quad (15)$$

其中, β 为自适应量子纠缠因子,可表示为:

$$\beta = 1 - \exp\left(-\frac{F_{\text{best},m} + F_{\text{best},f}}{2 \cdot \bar{F}}\right) \quad (16)$$

其中, $\bar{F}$ 为整个种群的平均适应度值, $F_{\text{best},m}$ 、 $F_{\text{best},f}$ 分别为雄性、雌性种群的最优个体适应度值。

2.3.2 遗传表观调控机制

标准SO算法的交配模式对所有个体采用相同的学习策略,忽略了种群个体间的性能差异,导致算法局部开采效率低。为此,本文引入遗传表观调控机制^[25],根据个体实时适应度水平动态调整其学习强度。该机制通过构建自适应遗传表观因子,精准区分优质个体与普通个体:优质个体被赋予更强的学习能力,引导种群向高性能区域收敛;普通个体则维持较高探索性,增强种群多样性。该机制显著提升了算法交配迭代过程的导向性与收敛效率,尤其适用于WSN覆盖这类复杂优化场景。其具体数学表达式为:

$$X_{i,m(f)}(t+1) = X_{i,m(f)}(t) + c_3 \cdot r \cdot M_{m(f)} \cdot (S_i \cdot Q \cdot X_{i,m(f)}(t) - X_{i,m(f)}(t)) \quad (17)$$

其中, S_i 为个体遗传强度,可表示为:

$$S_i = 0.8 + 0.4\eta_i \quad (18)$$

其中, η_i 为遗传表观因子,其数学表达式为:

$$\eta_i = \frac{1}{1 + \exp\left(-\frac{F_i - \bar{F}}{\sigma_F}\right)} \quad (19)$$

其中, $\bar{F}$ 和 σ_F 分别为种群适应度的平均值和标准差。实际迭代计算过程中,雄性种群和雌性种群可分别计算相应的 $\bar{F}$ 和 σ_F 值,实现分种群精准调控。

2.4 动态适应度排名策略

针对标准SO算法蛋孵化阶段固定替换率适应性差的问题,本文受自适应策略的启发^[26],对原有固定替换率模型进行了改进。通过引入动态适应度排名,实现了替换率随迭代进程的自适应调整。该策略在进化后期逐步降低替换比例,旨在更有效地维持种群多样性并保留优良个体。其中,动态替换率 p_{replace} 可表示为:

$$p_{\text{replace}} = 0.5 - \frac{t}{T} \cdot 0.3 \quad (20)$$

其中, T 为算法的最大迭代次数。

基于该动态替换率, 进一步计算待替换的个体数量 $b = \lfloor p_{\text{replace}} \cdot N \rfloor$ 。随后, 对种群中所有个体的适应度值进行升序排序, 筛选出适应度最低的个体, 并在可行解空间内随机生成新解对其进行替换。该策略有效平衡了种群多样性维持与算法收敛加速之间的博弈关系, 最终促使算法获得覆盖率高、分布均匀的无线传感器节点部署方案。

2.5 时间复杂度分析

设算法的最大迭代次数为 T , 种群规模 N , 问题维数为 D 。标准 SO 算法的种群初始化复杂度为 $O(ND)$ 。在迭代阶段, 算法执行种群适应度评价与最优个体搜寻, 以及基于探索/开发策略的位置更新, 这两项操作的时间开销均为 $O(ND)$ 。因此, 算法单次迭代的总体时间复杂度为 $O(ND)$, 总体时间开销则为 $O(TND)$ 。

相较于标准 SO 算法, 本文所提 MSSO 算法在初始化阶段融合 Tent 混沌映射与改进对立学习策略, 并在迭代阶段引入动态适应度排名策略, 其余改进策略均为位置更新逻辑的优化调整, 未引入新的复杂度项。据此分析, MSSO 算法的单次迭代复杂度上升为 $O(ND + N \log N)$ 。在 WSN 节点覆盖优化的常规场景下, 问题维数 D 往往远超 $\log N$, 算法复杂度仍由 $O(ND)$ 项主导。综上, MSSO 算法的整体时间复杂度为 $O(T(ND + N \log N))$, 与 SO 算法的时间复杂度仍处在同一量级。

3 WSN 节点覆盖优化设计

本文采用多策略融合改进蛇优化算法, 对 WSN 节点部署问题进行优化, 以解决因随机部署导致的网络覆盖率低的问题。在算法运行过程中, 需配置一系列关键参数, 并通过 MSSO 算法的迭代优化, 输出全局最优的节点部署方案及其对应的最大网络覆盖率。MSSO 算法的优化流程图如图 1 所示, 具体步骤如下。

步骤 1 构建基于离散网格的 WSN 布尔感知模型, 设定尺寸为 $L \times W$ 的目标监测区域, 并部署 N 个感知半径为 R 的同构传感器节点; 同时, 初始化算法控制参数 c_1 、 c_2 、 c_3 、温度及食物状态。

步骤 2 采用 Tent 混沌映射与改进对立学习策略生成初始种群, 表征不同的节点部署方案, 并将种群划分为雄性组与雌性组。

步骤 3 若 $Q < 0.25$, 采用随机—精英交替引导机制, 更新雄性 & 雌性种群中所有个体的位置。

步骤 4 若 $Q \geq 0.25$, 且温度 $K > 0.6$, 驱使个体向当前最优解移动, 更新其位置。

步骤 5 若 $Q \geq 0.25$, 且温度 $K \leq 0.6$, 按如下模式更新位置: 在斗争模式下采用自适应量子纠缠扰动策略; 在交配模式下引入遗传表观调控与动态替换机制。

步骤 6 判断是否达到最大迭代次数, 若未达到, 则使用新种群继续迭代并返回步骤 3; 否则, 终止优化, 输出最优节点部署方案。




图1 MSSO 算法的优化流程图

4 算法性能测试

4.1 基准函数测试

选择 11 个广泛使用的基准测试函数对 MSSO 算法的性能进行综合评价, 这些函数的定义及分类参考文献[9]和[27]。所采用的基准函数可分为三类, 包括 4 个单峰函数 (F1~F4)、4 个多峰函数 (F5~

F8) 以及3个混合复杂函数 (F9~F11)。基准测试函数的表达式与特性见表1。

为系统评估MSSO算法的综合优化性能, 本文选取灰狼优化 (gray wolf optimizer, GWO) 算法、鲸鱼优化 (whale optimization algorithm, WOA) 算法、人工蜂群算法 (artificial bee colony, ABC) 与标准SO算法作为对比算法, 开展基准函数仿真测试。实验从收敛速度、求解精度、全局搜索能力, 以及探索-开发平衡性能等多个方面, 对各算法的优化性能进行综合评价。为确保实验结果的公平性与结果可重复性, 所有对比算法均在统一的参数配置下独立运行20次, 并分别记录其最优值、平均值、最差值及标准差。基准函数测试结果见表2, 基准函数20次独立实验的平均收敛曲线如图2所示。

由表2数据与图2收敛曲线可知, GWO算法、WOA和ABC算法在不同类型的测试函数中各具优势: WOA算法在F1单峰函数上表现较优, 而ABC

算法在F7多峰函数上也展现出良好性能。相比之下, 标准SO算法在单峰、多峰及混合复合函数上的优化效果均较为一般。本文所提MSSO算法在绝大多数测试函数中均表现优异, 其性能不仅显著优于原始SO算法, 也整体优于其他对比算法。实验结果表明, MSSO算法具有优异的跳出局部极值的能力、强大的全局搜索性能, 以及应对复杂优化问题的良好鲁棒性。

4.2 工程应用测试

为验证MSSO算法在实际工程场景中的适用性与优化性能, 本文选取三个经典工程设计问题——压力容器设计、齿轮系设计与机器人夹持器设计——作为测试案例, 以综合评估MSSO算法在不同约束与复杂度下的表现。为保证对比实验的公平性, 在所有实验中, MSSO算法的初始种群规模统一设置为50, 最大迭代次数均为500次。该实验旨在全面评估MSSO算法在工程优化环境中的有效性、鲁棒性及

表1 基准测试函数的表达式与特性

函数表达式	维度	搜索范围	最优值	类别
$F1: F(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]^n$	0	单峰函数
$F2: F(x) = \max_i \{ x_i , 1 \leq i \leq n \}$	30	$[-100, 100]^n$	0	单峰函数
$F3: F(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]^n$	0	单峰函数
$F4: F(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1]$	30	$[-1.28, 1.28]^n$	0	单峰函数
$F5: F(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]^n$	-12 569.5	多峰函数
$F6: F(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]^n$	0	多峰函数
$F7: F(x) = \frac{\pi}{n} \left\{ 10 \sin^2(\pi y_i) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i, a, k, 4)$ $y_i = 1 + \frac{1}{4}(x_i + 1)$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a \leq x_i \leq a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	30	$[-50, 50]^n$	0	多峰函数
$F8: F(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^{n-1} (x_i - 1)^2 [1 + \sin^2(3\pi x_{i+1})] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	30	$[-50, 50]^n$	0	多峰函数
$F9: F(x) = -\sum_{i=1}^5 \left[(x - a_i)(x - a_i)^T + c_i \right]^{-1}$	4	$[0, 10]^n$	-10	混合函数
$F10: F(x) = -\sum_{i=1}^7 \left[(x - a_i)(x - a_i)^T + c_i \right]^{-1}$	4	$[0, 10]^n$	-10	混合函数
$F11: F(x) = -\sum_{i=1}^{10} \left[(x - a_i)(x - a_i)^T + c_i \right]^{-1}$	4	$[0, 10]^n$	-10	混合函数

表2 基准函数测试结果


函数	评价指标	SO 算法	GWO 算法	WOA 算法	ABC 算法	MSSO 算法
F1	最差值	$5.419\ 6\times 10^{-48}$	$8.411\ 9\times 10^{-21}$	$1.964\ 9\times 10^{-59}$	0.0018 955	$1.101\ 3\times 10^{-50}$
	最优值	$1.034\ 2\times 10^{-43}$	$2.559\ 7\times 10^{-19}$	$5.142\ 7\times 10^{-53}$	0.013 523	$1.554\ 7\times 10^{-44}$
	平均值	$6.218\ 2\times 10^{-45}$	$7.810\ 9\times 10^{-20}$	$2.606\ 9\times 10^{-54}$	0.006 760 1	$8.905\ 4\times 10^{-46}$
	标准差	$2.295\ 8\times 10^{-44}$	$6.525\ 2\times 10^{-20}$	$1.149\ 1\times 10^{-53}$	0.003 687 4	$3.454\ 2\times 10^{-45}$
F2	最差值	2.313×10^{-43}	$2.233\ 5\times 10^{-09}$	4.879 9	35.279 5	$1.468\ 4\times 10^{-44}$
	最优值	$3.693\ 5\times 10^{-40}$	$6.746\ 6\times 10^{-08}$	88.528 5	66.839 9	$1.520\ 2\times 10^{-41}$
	平均值	$2.829\ 5\times 10^{-41}$	$2.306\ 5\times 10^{-08}$	45.125 3	50.313 4	$2.774\ 1\times 10^{-42}$
	标准差	$8.135\ 2\times 10^{-41}$	$1.816\ 6\times 10^{-08}$	32.274 2	7.822 5	$4.255\ 4\times 10^{-42}$
F3	最差值	2.618 2	25.772 8	26.628 3	3.008 7	0.044 646
	最优值	148.733 3	28.738	28.731 6	98.733 2	28.944 1
	平均值	35.806	26.705 5	27.404 2	34.103 9	11.508 1
	标准差	37.401 2	0.804 83	0.449 39	29.917 6	12.791 2
F4	最差值	$1.914\ 6\times 10^{-05}$	0.000 196 79	$4.678\ 5\times 10^{-05}$	0.142 06	$2.191\ 1\times 10^{-06}$
	最优值	0.000 472 42	0.002 933 2	0.005 497 8	0.426 77	0.000 324 41
	平均值	0.000 203 99	0.001 072 2	0.001 436	0.269 35	0.000 112 09
	标准差	0.000 119 23	0.000 775 01	0.001 568 8	0.071 973	$8.402\ 3\times 10^{-05}$
F5	最差值	-12 569.484 7	-7 354.314 2	-12 568.364 6	-11 831.771 4	-12 569.482 7
	最优值	-11 987.004 4	-5 354.247 8	-8 222.175	-11 210.581 8	-12 471.005 5
	平均值	-12 486.636 8	-6 448.465 9	-11 170.191 9	-11 492.154 6	-12 554.280 8
	标准差	132.535 3	508.574 6	1 546.735 4	160.59	25.388 6
F6	最差值	0	0	0	0.000 134 86	0
	最优值	0.125 6	0.027 009	0.037 979	0.047 037	0
	平均值	0.020 985	0.002 036 2	0.001 898 9	0.012 84	0
	标准差	0.035 711	0.006 628	0.008 492 3	0.014 512	0
F7	最差值	0.000 557 72	0.005 843 1	0.001 394 3	$4.398\ 5\times 10^{-07}$	$1.623\ 3\times 10^{-07}$
	最优值	0.053 578	0.057 785	0.265 63	0.000 217 62	0.039 477
	平均值	0.017 008	0.026 503	0.019 177	$3.352\ 9\times 10^{-05}$	0.010 06
	标准差	0.011 98	0.014 244	0.058 258	$5.031\ 7\times 10^{-05}$	0.011 835
F8	最差值	0.012 65	0.101 12	0.046 483	$1.136\ 9\times 10^{-05}$	$2.677\ 8\times 10^{-09}$
	最优值	0.766 27	0.732 13	0.642 23	0.000 734 91	0.582 74
	平均值	0.179 74	0.356 74	0.224 94	0.000 204 05	0.114 51
	标准差	0.196 21	0.178 16	0.151 23	0.000 217 82	0.135 6
F9	最差值	-10.153 2	-10.152 9	-10.152 8	-10.153 2	-10.153 2
	最优值	-9.698 7	-5.099 1	-2.630 5	-10.056 6	-10.153 2
	平均值	-10.106 9	-9.899 3	-9.005 5	-10.147 8	-10.153 2
	标准差	0.1089 7	1.129 9	2.386 9	0.021 606	$2.305\ 3\times 10^{-15}$
F10	最差值	-10.402 9	-10.402 8	-10.402 9	-10.402 9	-10.402 9
	最优值	-8.878 4	-10.399 4	-2.765 7	-10.389 3	-10.402 9
	平均值	-10.269 4	-10.401 6	-8.395 7	-10.402 2	-10.402 9
	标准差	0.364 91	0.000 812 24	2.845 5	0.003 045 3	$3.844\ 6\times 10^{-15}$
F11	最差值	-10.536 4	-10.536 3	-10.536 2	-10.536 4	-10.536 4
	最优值	-9.726 1	-10.533 6	-1.859 3	-10.507 9	-10.536 4
	平均值	-10.449 9	-10.535 2	-9.024 5	-10.534 5	-10.536 4
	标准差	0.210 43	0.000 832 13	3.073 2	0.006 674 4	2.269×10^{-15}

实用价值。

4.2.1 压力容器设计问题

压力容器设计 (pressure vessel design, PVD) ^[28]

是一个经典的工程优化问题,其目标是在满足生产工艺要求的前提下,最小化总制造成本 $f(x)$ 。该问题包含4个设计变量:内半径(记为 x_1)、容器长度






图2 基准函数收敛曲线

(记为 x_2)、外壳厚度(记为 x_3)和封头厚度(记为 x_4)。其目标函数可以表示为:

$$\begin{aligned} \min f(x) = & 0.6224x_1x_3x_4 + 1.7781x_2x_3^2 + \\ & 3.1661x_1^2x_4 + 19.84x_1^2x_3, 0 \leq x_1 \leq 99, \\ & 0 \leq x_2 \leq 99, 10 \leq x_3 \leq 200, 10 \leq x_4 \leq 200 \end{aligned} \quad (21)$$

$$\text{st. } g_1(x) = -x_1 + 0.0193x_3 \leq 0$$

$$g_2(x) = -x_2 + 0.00954x_3 \leq 0$$

$$g_3(x) = -\pi x_2^2 x_4 - \frac{4}{3} \pi x_3^3 + 1\,296\,000 \leq 0$$

$$g_4(x) = x_4 - 240 \leq 0$$

各算法在压力容器设计问题上的优化结果见表3。

由表3数据可以看出, MSSO算法所获得的最小制造成本为5 886.38, 在所有对比算法中最低。实验结果表明, 在此类带有复杂约束的工程优化问题中, MSSO算法相较于标准SO算法及其他对比算法, 表现出更优异的优化性能, 能够稳定地寻得更经济、更合理的设计方案。各算法在压力容器设计问题上的收敛曲线如图3所示。

4.2.2 齿轮系设计问题

齿轮系设计是机械工程领域的一个典型无约束离散优化问题^[29], 其目标是 minimized 齿轮系统的传动比。该传动比为输出轴角速度与输入轴角速度之比。本文以4个齿轮的齿数作为设计变量, 即 n_1 、 n_2 、

表3 各算法在压力容器设计问题上的优化结果

算法	内半径(x_1)	容器长度(x_2)	外壳厚度(x_3)	封头厚度(x_4)	最小化制造成本
SO	1.115 816	0.551 549	57.814 316	46.333 904	6 749.129 837
DBO	1.258 847	0.622 249	65.225 233	10.000 000	7 319.000 702
HHO	1.060 867	0.525 264	54.900 803	63.665 612	6 575.685 161
GWO	0.780 308	0.388 558	40.415 671	198.855 696	5 903.329 548
WFO	7.071 345	4.516 893	92.482 311	47.538 655	$1.873\,2 \times 10^{+05}$
GOA	1.085 983	0.535 852	56.147 475	56.054 713	6 654.137 383
MSSO	0.778 172	0.385 002	40.319 626	200.000 000	5 886.381 212




图3 各算法在压力容器设计问题上的收敛曲线

n_3 和 n_4 。该问题的数学模型可表示为：

$$f(X) = \left(\frac{1}{6.931} - \frac{n_3 n_2}{n_1 n_4} \right)^2, 12 \leq n_i \leq 60, i = 1, 2, 3, 4 \quad (22)$$

各算法在齿轮系设计问题上的优化结果见表4。从表4可以看出，MSSO算法所获得的最小齿轮比为 2.701×10^{-12} ，在所有对比算法中最低。实验结果表明，在此类无约束离散优化问题中，MSSO算法相较于标准SO算法及其他对比算法，表现出更优异的寻优能力，能够有效获得更符合设计目标的齿轮参数方案。各算法在齿轮系设计问题上的收敛曲线如图4所示。

表4 各算法在齿轮系设计问题上的优化结果

算法	齿数				最小齿轮比
	齿轮1	齿轮2	齿轮3	齿轮4	
SO	51	26	15	53	2.307816×10^{-11}
DBO	55	34	14	60	1.361649×10^{-9}
HHO	33	14	17	50	1.361649×10^{-9}
GWO	47	12	13	23	9.921580×10^{-10}
WFO	33	12	17	43	2.663708×10^{-7}
GOA	32	12	15	39	2.357641×10^{-9}
MSSO	43	16	19	49	2.700857×10^{-12}




图4 各算法在齿轮系设计问题上的收敛曲线

4.2.3 机器人夹持器设计问题

机器人夹持器设计^[30]是机器人结构优化中的一个典型问题，其目标是在满足多种非线性约束的前提下，极小化夹持器输出力的峰值与谷值之差，以提高夹持操作的稳定性和适应性。该问题包含7个与机

器人机构尺寸及力学性能相关的设计变量，分别记为 a 、 b 、 c 、 e 、 f 、 l 、 δ 。其中， a 为连杆a长度， $10 \leq a \leq 150$ ； b 为连杆b长度， $10 \leq b \leq 150$ ； c 为驱动杆长度， $100 \leq c \leq 200$ ； e 为偏置距离； $0 \leq e \leq 50$ ； f 为夹持端基础尺寸， $10 \leq f \leq 150$ ； l 为滑轨总长度， $100 \leq l \leq 300$ ； δ 为机构角度变量， $1 \leq \delta \leq \pi$ 。该问题同时受到7个非线性不等式约束的限制。该问题的数学模型可表示为：

$$\min f(\bar{x}) = -\min_z F_k(x, z) + \max_z F_k(x, z) \quad (23)$$

$$\text{st. } g_1(\bar{x}) = -Y_{\min} + y(\bar{x}, Z_{\max}) \leq 0$$

$$g_2(\bar{x}) = -y(\bar{x}, Z_{\max}) \leq 0$$

$$g_3(\bar{x}) = Y_{\max} - y(\bar{x}, 0) \leq 0$$

$$g_4(\bar{x}) = y(\bar{x}, 0) - Y_G \leq 0$$

$$g_5(\bar{x}) = l^2 + e^2 - (a + b)^2 \leq 0$$

$$g_6(\bar{x}) = b^2 - (a - e)^2 - (l - Z_{\max})^2 \leq 0$$

$$g_7(\bar{x}) = Z_{\max} - l \leq 0$$

$$\alpha = \cos^{-1} \left(\frac{a^2 + g^2 - b^2}{2ag} \right) + \phi \quad (24)$$

$$g = \sqrt{e^2 + (z - l)^2} \quad (25)$$

$$\beta = \cos^{-1} \left(\frac{b^2 + g^2 - a^2}{2bg} \right) - \phi \quad (26)$$

$$\phi = \tan^{-1} \left(\frac{e}{l - z} \right) \quad (27)$$

$$y(x, z) = 2(f + e + c \sin(\beta + \delta)) \quad (28)$$

$$F_k = \frac{Pb \sin(\alpha + \beta)}{2c \cos(\alpha)} \quad (29)$$

z 为滑块位移； $Y_{\min}$ 、 $Y_{\max}$ 分别为夹持行程的上下限，本文分别取50、100； Y_G 为夹持器最大开口尺寸，本文取150； $Z_{\max}$ 为滑块最大位移，本文取100； P 为驱动力，本文取100。

各算法在机器人夹持器设计问题上的优化结果见表5。由表5数据可知，MSSO算法所获得的输出力波动为 1.719×10^{-16} ，与最优值极为接近，虽未达到最优，但显著优于标准SO算法。实验结果表明，在此类多变量非线性约束优化问题中，MSSO算法在竞争力与稳定性方面表现出明显优势，能够有效获得满足复杂工程约束且性能良好的可行方案。各算法在机器人夹持器设计问题上的收敛曲线如图5所示。

5 覆盖优化实验仿真与分析

为客观、全面地评估MSSO算法在WSN覆盖

表5 各算法在机器人夹持器设计问题问题的优化结果

算法	a	b	c	e	f	l	δ	输出力波动值
SO	150.000	102.733 73	172.678 210	46.114 70	149.520 73	126.686 110	3.140 000	4.077 173
DBO	99.999 9	38.196 497	100.000 000	0	10.000 000	100.000 000	1.288 763	1.455×10^{-16}
HHO	150.000	139.546 21	146.581 482	0.805 87	137.918 29	184.578 117	2.837 663	5.322 799
GWO	149.936	146.455 18	183.913 057	1.763 27	121.660 38	144.243 103	2.394 989	3.527 084
WFO	141.413	113.088 56	147.435 965	17.974 0	121.860 31	190.000 341	2.978 676	10.283 437
GOA	99.971 9	38.168 536	100.000 000	0	10.000 000	100.000 000	1.062 770	1.458×10^{-16}
MSSO	98.413 0	36.383 564	100.000 000	0	45.673 946	100.000 000	1.577 324	1.719×10^{-16}




图5 各算法在机器人夹持器设计问题上的收敛曲线

优化中的性能与优势，在统一仿真实验环境下开展多组对比验证。所有实验均在MATLAB R2022a平台中编程实现并执行，仿真关键参数设置如下：监测区域为50 m×50 m的二维正方形区域，传感器节点数量为40个，种群规模为100，感知半径设为5 m^[15-16]，并针对各算法的收敛特性，设置相应的最大迭代次数。

5.1 与单阶段改进算法对比

在相同实验参数条件下对各算法开展性能仿真对比，传感器节点随机初始化后的覆盖分布如图6所示，SO算法的覆盖分布如图7所示，采用Tent混沌映射与改进对立学习策略的蛇优化（TSO）算法的




图6 传感器节点随机初始化后的覆盖分布




图7 SO算法的覆盖分布

覆盖分布如图8所示，基于循环寻优阶段改进策略的蛇优化（JSO）算法的覆盖分布如图9所示，MSSO算法的覆盖分布如图10所示，各算法随迭代次数增加的覆盖率变化曲线如图11所示。




图8 TSO算法的覆盖分布

对比图6至图10可以看出，图7至图10的优化后部署相较于图6的随机初始部署均有显著改进。其中，标准SO算法的部署仍存在较大覆盖盲区；




图9 JSO算法的覆盖分布




图10 MSSO算法的覆盖分布




图11 各算法随迭代次数增加的覆盖率变化曲线

TSO算法与JSO算法在SO算法基础上均有一定改善,但仍未完全消除覆盖盲区。相比之下,经MSSO算法优化后的节点分布更为均匀,覆盖盲区显著减少,展现出更优的整体覆盖性能。

结合图11各算法的收敛曲线可知,4种蛇优化算法在提升WSN覆盖率方面表现出明显差异。标准

SO算法收敛性能有限,最终覆盖率仅为93.28%,存在明显的感知盲区;TSO算法与JSO算法分别达到了95.40%与97.32%的覆盖率,性能较SO算法均有提升;而MSSO算法展现出了更优越的收敛性能,覆盖率最高,达到98.52%,显著优于其他3种对比算法。

5.2 与其他改进算法对比

为验证MSSO算法的有效性,将其与标准So算法、文献[15]提出的ISO算法(以下简称ISO-I)、文献[16]提出的ISO算法(以下简称ISO-II),以及文献[31]提出的WOA-GWO算法进行对比分析。5种算法的仿真实验均在前文所述的实验环境下进行,以确保结果的可比性。各算法在设定迭代次数内达到的最终覆盖率见表6。

表6 各算法在设定迭代次数内达到的最终覆盖率

算法	迭代次数	最终覆盖率
SO	1 000	93.28%
ISO-I	1 000	98.12%
WOA-GWO	500	97.88%
ISO-II	500	98.14%
MSSO	500	98.52%

由表6可知,标准SO算法的优化能力有限,最终覆盖率为93.28%。ISO-I算法虽将覆盖率提升至98.12%,但需经过1 000次迭代才可充分收敛。WOA-GWO和ISO-II算法均表现出较快的收敛速度,在500次迭代时覆盖率分别达到97.88%和98.14%。MSSO算法在500次迭代时覆盖率即达到98.52%,显著优于同等迭代次数下的对比算法,同时也超过多数算法在1 000次迭代后的性能。与标准SO算法相比,MSSO覆盖率绝对提升5.24个百分点。综上,MSSO算法在收敛速度和优化精度方面均具有显著优势,验证了其作为WSN覆盖优化方法的有效性。

6 结束语

针对WSN节点随机部署引发的覆盖空洞、节点分布失衡,以及网络能效偏低等问题,本文提出了一种多策略融合改进蛇优化算法(MSSO)。MSSO算法运用Tent混沌映射与改进对立学习策略生成高质量初始种群,借助随机一精英交替引导机制强化全局探索能力,并引入自适应量子竞争纠缠与遗传表观调控机制以协调种群多样性与收敛速度,再通过动态适应度排名策略实现种群选择压力的自适应

调控。仿真实验结果表明, MSSO 算法能够有效改善 WSN 覆盖质量与分布均匀性, 在迭代 500 次时的覆盖率达 98.52%, 且在基准函数与三类典型工程优化问题中也展现出了良好的泛化性能与鲁棒性。总体而言, MSSO 算法不仅为 WSN 覆盖优化提供了一种可靠途径, 而且通用性与稳定性较强, 具备拓展至各类复杂优化场景的潜力。后续研究将重点探究该算法在动态环境、多目标优化, 以及大规模传感器网络中的适应能力与应用前景。

参考文献:

- [1] Tsai C W, Hong T P, Shiu G N. Metaheuristics for the lifetime of WSN: a review[J]. *IEEE Sensors Journal*, 2016, 16(9): 2812-2831.
- [2] Zaimen K, Brahmia M E A, Moalic L, et al. A survey of artificial intelligence based WSNs deployment techniques and related objectives modeling[J]. *IEEE Access*, 2022, 10: 113294-113329.
- [3] 朱洪波, 尹浩. 智能化时代的物联网科技与产业发展分析及策略[J]. *物联网学报*, 2025, 9(3): 1-16.
Zhu H B, Yin H. Analysis and strategies of IoT technology and industrial development in the intelligent era[J]. *Chinese Journal on Internet of Things*, 2025, 9(3): 1-16.
- [4] 陈江南, 陈旭彬, 邓硕, 等. 基于 ESP8266 的智能家居火灾监测系统设计与实现[J]. *物联网技术*, 2025, 15(17): 16-20, 26.
Chen J N, Chen X B, Deng Q, et al. Design and implementation of smart home fire monitoring system based on ESP8266[J]. *Internet of Things Technologies*, 2025, 15(17): 16-20, 26.
- [5] 李守定, 乔华, 马世伟, 等. 基于温度-降雨双参数的新疆地质灾害预警模型[J]. *水利水电技术(中英文)*, 2021, 52(11): 207-218.
Li S D, Qiao H, Ma S W, et al. Temperature-rainfall dual parameter-based early warning model for geological disasters in Xinjiang[J]. *Water Resources and Hydropower Engineering*, 2021, 52(11): 207-218.
- [6] 苟平章, 孙现超, 毛刚. 基于改进遗传算法的覆盖空洞修复优化[J]. *传感技术学报*, 2020, 33(12): 1800-1807.
Gou P Z, Sun X C, Mao G. Optimization of recovering coverage holes based on improved genetic algorithm[J]. *Chinese Journal of Sensors and Actuators*, 2020, 33(12): 1800-1807.
- [7] Egwuche O S, Singh A, Ezugwu A E, et al. Machine learning for coverage optimization in wireless sensor networks: a comprehensive review[J]. *Annals of Operations Research*, 2023: 1-67.
- [8] Kennedy J, Eberhart R. Particle swarm optimization[C]//*Proceedings of ICNN'95 - International Conference on Neural Networks*. Piscataway: IEEE Press, 1995: 1942-1948.
- [9] Mirjalili S, Lewis A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [10] Xue J K, Shen B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [11] 陈立万, 赵尚飞, 曾蝶, 等. 基于混合策略麻雀搜索算法的 WSN 覆盖优化[J]. *电子测量技术*, 2022, 45(23): 174-180.
Chen L W, Zhao S F, Zeng D, et al. WSN coverage optimization based on hybrid strategy sparrow search algorithm[J]. *Electronic Measurement Technology*, 2022, 45(23): 174-180.
- [12] 王振东, 王建兰, 王俊岭, 等. 融合多策略学习型麻雀搜索算法的 UWSN 覆盖优化[J]. *传感技术学报*, 2024, 37(8): 1424-1433.
Wang Z D, Wang J L, Wang J L, et al. UWSN coverage optimization based on multi-strategy learning sparrow search algorithm[J]. *Chinese Journal of Sensors and Actuators*, 2024, 37(8): 1424-1433.
- [13] 周恺卿, 杨森宇, 康棣文, 等. 基于改进布谷鸟搜索算法的无线传感器网络覆盖优化[J]. *河南理工大学学报(自然科学版)*, 2025, 44(4): 48-58, 141.
Zhou K Q, Yang S Y, Kang D W, et al. Coverage optimization in wireless sensor networks based on improved cuckoo search algorithm[J]. *Journal of Henan Polytechnic University (Natural Science)*, 2025, 44(4): 48-58, 141.
- [14] 程仁轩, 徐凯宏, 高俊哲, 等. 改进蛇算法的无线传感网络覆盖优化研究[J]. *火力与指挥控制*, 2025, 50(7): 80-87.
Cheng R X, Xu K H, Gao J Z, et al. Research on optimization of wireless sensor network coverage with improved snake algorithm[J]. *Fire Control & Command Control*, 2025, 50(7): 80-87.
- [15] 李振, 冯锋. 基于改进蛇优化算法的 WSN 覆盖研究[J]. *计算机技术与发展*, 2024, 34(3): 89-95.
Li Z, Feng F. Research on WSN coverage based on improved snake optimizer algorithm[J]. *Computer Technology and Development*, 2024, 34(3): 89-95.
- [16] 张勇, 唐睿哲, 刘畅, 等. 基于改进蛇优化算法的 WSN 覆盖优化研究[J]. *电子测量技术*, 2024, 47(16): 24-32.
Zhang Y, Tang R Z, Liu C, et al. Research on WSN coverage optimization based on improved snake optimization algorithm[J]. *Electronic Measurement Technology*, 2024, 47(16): 24-32.
- [17] Zaimen K, Brahmia M E A, Moalic L, et al. A comparative study of meta-heuristic algorithms for WSN deployment problem in indoor environments[C]//*Proceedings of the 2023 IEEE Congress on Evolutionary Computation (CEC)*. Piscataway: IEEE Press, 2023: 1-8.
- [18] Hashim F A, Hussien A G. Snake optimizer: a novel meta-heuristic optimization algorithm[J]. *Knowledge-Based Systems*, 2022, 242: 108320.
- [19] Wang J M, Zhu Z L, Zhang F, et al. An improved salp swarm algorithm for solving node coverage optimization problem in WSN[J]. *Peer-to-Peer Networking and Applications*, 2024, 17(3): 1091-1102.
- [20] Jonker R, Volgenant A. A shortest augmenting path algorithm for dense and sparse linear assignment problems[J]. *Computing*, 1987, 38(4): 325-340.
- [21] Li Y C, Han M X, Guo Q L. Modified whale optimization algorithm based on tent chaotic mapping and its application in structural optimization[J]. *KSCE Journal of Civil Engineering*, 2020, 24(12): 3703-3713.
- [22] Mahdavi S, Rahnamayan S, Deb K. Opposition based learning: a

literature review[J]. Swarm and Evolutionary Computation, 2018, 39: 1-23.

- [23] Wang Z D, Xie H M, Hu Z D, et al. Node coverage optimization algorithm for wireless sensor networks based on improved grey wolf optimizer[J]. Journal of Algorithms & Computational Technology, 2019, 13: 1748302619889498.
- [24] Turkeshi X, Piroli L, Schiró M. Enhanced entanglement negativity in boundary-driven monitored Fermionic chains[J]. Physical Review B, 2022, 106(2): 024304.
- [25] Jogam P, Sandhya D, Alok A, et al. A review on CRISPR/Cas-based epigenetic regulation in plants[J]. International Journal of Biological Macromolecules, 2022, 219: 1261-1271.
- [26] Kara D, Kimura T, Chen Y T, et al. PhyMask: an adaptive masking paradigm for efficient self-supervised learning in IoT[C]//Proceedings of the 22nd ACM Conference on Embedded Networked Sensor Systems. New York: ACM, 2024: 97-111.
- [27] Di Carlo M, Vasile M, Minisci E. Adaptive multi-population inflationary differential evolution[J]. Soft Computing, 2020, 24(5): 3861-3891.
- [28] 王丽娟, 刘姝含, 王剑, 等. 结合精英初始化和 K 近邻的蛇优化算法[J]. 计算机应用研究, 2024, 41(9): 2712-2721.
- Wang L J, Liu S H, Wang J, et al. Snake optimization algorithm combining elite initialisation and K -nearest neighbors[J]. Application Research of Computers, 2024, 41(9): 2712-2721.
- [29] Kannan B K, Kramer S N. An augmented Lagrange multiplier based method for mixed integer discrete continuous optimization and its applications to mechanical design[J]. Journal of Mechanical Design, 1994, 116(2): 405-411.
- [30] Hernandez J, Sunny M S H, Sanjuan J, et al. Current designs of robotic arm grippers: a comprehensive systematic review[J]. Robotics, 2023, 12(1): 50.
- [31] 李振, 冯锋. 基于Halton序列WOA-GWO算法的WSN覆盖研究[J]. 物联网技术, 2024, 14(2): 43-47, 51.
- Li Z, Feng F. Research on WSN coverage based on Halton sequence WOA-GWO algorithm[J]. Internet of Things Technologies, 2024, 14(2): 43-47, 51.

[作者简介]



李胜锋(2001—), 男, 宁夏师范大学数学与计算机科学学院硕士生, 主要研究方向为智能优化算法、无线传感器网络覆盖优化。



田彦山(1979—), 男, 宁夏师范大学数学与计算机科学学院教授、硕士生导师, 主要研究方向为并行与分布式计算、嵌入式计算、边缘计算。



马旭(1970—), 男, 宁夏师范大学数学与计算机科学学院教授、硕士生导师, 主要研究方向为计算机软件与理论、云计算、大数据。



张芳琴(1982—), 女, 宁夏师范大学数学与计算机科学学院副教授, 主要研究方向为嵌入式系统、无线网智能系统。



杨金米(1996—), 女, 宁夏师范大学数学与计算机科学学院助教, 主要研究方向为图像处理、模式识别。



马甜甜(1998—), 女, 宁夏师范大学数学与计算机科学学院助教, 主要研究方向为LTE、无线网络。



罗晓丽(1990—), 女, 博士, 宁夏师范大学数学与计算机科学学院副教授、硕士生导师, 主要研究方向为模式识别、光学分子图像、目标检测、医学图像分析。