用于增强无线传感器网络覆盖的多策略改进北方苍鹰优化

1st Yiran Tian牡丹江师
范学院中国，黑龙江省
157000
tyr199810@163.com

2ndYuanjia Liu西安理
工大学中国，陕西省
710000 minato
liu@outlook.com

arXiv:2601.01898v1 [cs.NE] 5 Jan 2026

摘要——**为提高无线传感器网络的覆盖率，本文提出一种基于多策略融合北方苍鹰优化算法（NGO）的先进优化策略。具体而言，首先采用多变量混沌映射提高初始种群的随机性和均匀性。为进一步增强种群多样性并防止算法陷入局部最优，在追逐与逃逸阶段之后引入双向种群进化动力学策略，从而有助于获得全局最优解。通过大量仿真实验评估所提出的多策略NGO 在无线传感器网络覆盖中的性能。实验结果表明，在提升覆盖率和节点连通性方面，所提出的算法均显著优于现有基准算法。**

索引词—**无线传感器网络、北方苍鹰优化算法、多样化混沌映射初始化策略、双向种群进化动力学，插入**

I. 引言

无线传感器网络（WSN）是一种分布式智能系统，由大量配备感知、计算和无线通信能力的微型低功耗节点组成。这些节点通常通过自组织和多跳数据传输形成网络 [1] [2]。每个传感器节点协同感知、收集、处理并传输监测区域内有关目标对象的数据，发送至中心汇聚节点，以供用户分析和决策。

此类网络的性能主要取决于其监测覆盖率 [3]。然而，实际部署往往存在节点分布不均的问题，导致感知冗余和覆盖空洞，最终造成硬件资源的严重浪费 [4] [5]。因此，覆盖优化已成为无线传感器网络研究领域最关键的挑战之一。

在无线传感器网络中，实现最优网络覆盖被归类为 NP 难问题，这意味着找到精确解需要大量计算，且往往难以实现在合理的时间范围内 [6]。鉴于这一复杂性，群体智能（SI）优化算法已成为一种可靠的替代方案，可用于寻找高质量的近似解。受自然过程启发，群体智能算法已被证明是应对无线传感器网络中多方面挑战的有效工具。这些元启发式算法在事件检测和查询处理方面尤为有效，从而提高了在监测领域识别现实世界事件的精确度和可靠性 [7] [8]。

群体智能算法适用于 NP-hard 问题，原因在于它们能够高效探索广阔而复杂的搜索空间。确保传感器节点收集的数据准确可靠，涉及多种复杂因素，包括协议设计、集成异常检测技术，以及应用仿生启发式算法来简化数据处理 [9]。通过这些协同优化工作，群体智能算法有助于生成可信数据，最终提升无线传感器网络的整体性能和实用价值。

为应对无线传感器网络中的覆盖优化挑战，研究人员开发并部署了多种改进的群体智能元启发式算法。例如，Toloueiash-tian 等人 [10]提出了一种针对点覆盖问题改进的鲸鱼优化算法（WOA）。通过优化 WOA 的三种核心机制——探索、螺旋攻击和气泡网搜索，该方法显著提高了覆盖率，并找到了最优节点配置。同样，Akram 等人 [11] 提出了一种采用自适应学习自动机的策略。通过赋予传感器节点自主学习能力，网络可以在任何时刻动态选择合适的状态，从而优化整体覆盖性能。

针对高部署成本和有效覆盖不足等具体问题，Ou等人 [12] 开发了一种多策略灰狼优化器（GWO）。该方法融入了多种改进策略，有助于算法避免早熟收敛并摆脱局部最优。此外，为了缓解异构无线

请在此处填写适用的资助机构。如无，请删除此内容。

传感器网络（HWSNs）随机部署过程中的覆盖盲区和冗余问题，Cao等人 [13] 提出了一种基于改进社交蜘蛛优化算法（SSO）的优化策略。具体而言，他们引入混沌初始化以加速全局收敛，并采用改进的邻域搜索、全局搜索和匹配半径机制，以提高搜索效率。该方法不仅提升了网络覆盖，还有效降低了能量消耗。

除了满足监测区域的感知需求外，面向覆盖的无线传感器网络的设计还必须严格考虑能量消耗。因此，大量研究致力于在保持较高覆盖质量的同时延长网络运行寿命 [14]。例如，Yarinezhad和Hashemi [15] 提出了一种针对目标覆盖问题的传感器部署方法，利用两种改进型粒子群优化（PSO）算法，同时最大化覆盖范围和网络寿命。

为解决传统覆盖模型的局限性，Elhoseny等人 [16] 采用遗传算法（GA）优化无线传感器网络覆盖。该方法确保在能源资源受限的条件下，对指定目标进行尽可能长时间的连续监测，从而显著提升网络生命周期和吞吐量。此外，一些研究人员将区域覆盖缓解技术与高效的聚类方法相结合，以优化能量利用。一个典型例子是区域覆盖感知聚类协议（ACACP），该协议在传感器激活、网络聚类和多跳通信阶段优化功耗，在不影响感知范围的情况下延长整个系统的使用寿命[17]。

受苍鹰捕食行为启发的北方苍鹰优化算法（NGO）凭借强大的搜索能力和并行处理潜力，在解决复杂优化问题方面展现出显著潜力 [18]。尽管具有这些优势，标准 NGO 仍面临若干关键瓶颈，包括容易陷入局部最优、随机初始化导致初始种群多样性不足，以及探索与开发之间存在固有失衡。

为缓解这些局限性，研究人员提出了多种增强型NGO算法。例如，Liang等人 [19]通过将多项式插值策略与多样化的反向学习方法相结合，引入了增强型北方苍鹰优化算法（ENGO）。这种混合方法能够有效维持探索与开发之间的动态平衡，从而促进针对高维问题的高质量解更快收敛。类似地，Sadeeq和Abdulazeez [20] 提出了一种在探索阶段与开发阶段之间进行切换的创新模式切换机制，并结合莱维飞行来增强全局搜索能力，防止陷入局部最优而停滞。此外，Zeng等人 [21] 开发了一种面向全局优化和工程设计的多策略改进型北方苍鹰优化算法，专门针对早熟收敛和局部陷阱问题。

为克服 NGO 算法易陷入局部极值的固有缺陷，并进一步提升无线传感器网络模型的覆盖性能，本文提出了一种多策略改进北方苍鹰优化（INGO）算法。所提出的 INGO 框架采用多变量混沌映射进行种群初始化，并融合了双向种群进化动力学策略。这些改进旨在提升全局搜索效率，并确保探索与开发之间保持稳健平衡。

借助 INGO 算法，我们对无线传感器网络模型的覆盖率和节点连通性进行了优化。为严格验证所提方法的优越性，我们开展了大量对比实验。实验将 INGO 的性能与标准 NGO、人工蜂群算法（ABC） [22], 、改进野马优化器（IWHO） [23],以及基于萤火虫算法（FA）的部署方法 [24]进行了比较。实验结果表明，INGO 算法能够有效实现更优的覆盖优化效果和连通性，始终优于上述先进元启发式算法。

本文其余部分安排如下：第二节介绍无线传感器网络覆盖模型和问题建模；第三节详细介绍所提出的 INGO 算法及其各项策略；第四节给出实验结果和对比分析；最后，第五节总结全文并讨论未来研究方向。

II. 相关工作

A. 系统建模与问题建模

假设监测区域是一个大小为 $L \times M$ 的二维平面，其中随机部署了 N 个同质传感器节点。在该无线传感器网络架构中，每个节点的感知范围建模为以节点位置为中心的圆形区域。令 R 表示感知半径， R_c 表示通信半径，并以运行约束 $R_c \geq 2R$ 确保网络无缝连通。传感器节点集合定义为 $S = \{s_1, s_2, s_3....s_n\}$。

假设传感器节点 v_i 位于 (x_i, y_i)，目标点 u_j 位于 (x_j, y_j)。节点 v_i 与目标点 u_j 之间的欧几里得距离记为 $d(v_i, u_j)$，计算如下 [25]:

$$d(v_i, u_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \tag{1}$$

根据布尔感知模型，如果目标 u_j位于节点 v_i的圆形感知范围内，则感知质量为 1；否则为 0。因此，节点 v_i 相对于目标 u_j 的感知概率 $p(v_i, u_j)$定义如下:

$$p(v_i, u_j) = \begin{cases} 1, d(v_i, u_j) \leq R \\ 0, d(v_i, u_j) > R \end{cases} \tag{2}$$

在实际场景中，监测区域内的单个目标可能同时被多个传感器感知。为此，将各个感知概率汇总为联合感知概率，定义如下：

$$p(v_i,u_j)=1-\prod_{i=1}^{N}[1-p(v_i,u_j)] \tag{3}$$

其中，N 表示部署在该区域内的传感器节点总数。

覆盖率是评估无线传感器网络 [26]性能的一项基本指标。从结构上看，覆盖率定义为有效覆盖区域与监测区域总面积之比。将该区域离散为网格点后，整体覆盖率 Cov 可表示如下：

$$Cov=\frac{\sum_{j=1}^{L\times M}p(v_i,u_j)}{L\times M} \tag{4}$$

本研究将公式（4）中的 Cov 作为目标函数，所提出的改进算法旨在最大化该函数，以确定最优节点配置。

为评估无线传感器网络的覆盖性能，建立了如图 1 所示的数值仿真环境。仿真过程如下：

区域离散化：将监测区域划分为大小相等的均匀网格，并在每个网格单元的中心设置一个离散监测点（在仿真中以黑色星形表示）。

覆盖判据：当且仅当某监测点到最近传感器节点的欧几里得距离小于或等于感知半径 R时，才认为该监测点被“覆盖”。

近似精度：总体网络覆盖率计算为所有已覆盖网格的累计面积与监测区域总面积之比。

收敛：随着网格粒度增加（即离散化程度提高），计算得到的覆盖率渐近地接近网络的真实物理覆盖水平。

B. 标准北方苍鹰优化算法

北方苍鹰优化算法（NGO） [27]是一种基于种群的元启发式算法，其灵感来源于苍鹰的策略性捕猎行为。搜索智能体代表单个苍鹰，通过两个阶段的过程在解空间中进行搜索：

阶段1：猎物识别与快速突袭：该阶段模拟对猎物的初始探测与迅速攻击，主要促进全局探索，以识别搜索空间中的潜在区域。

阶段2：追逐与逃逸：此阶段模拟猎物试图逃跑时随后发生的追击，着重于细粒度的局部开发，以推动种群趋近全局最优解。

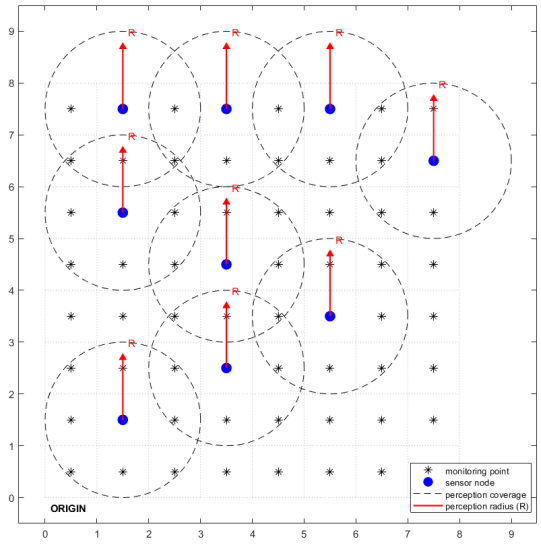

图1. 无线传感器网络覆盖

1) 阶段*1*：猎物识别与攻击（探索）：在第一阶段，北方苍鹰会随机选择一只猎物并迅速发起突袭。通过在整个搜索空间中随机选择猎物，NGO算法执行大范围的全局搜索，以定位最优区域。该随机行为的数学表达如下：

$$P_i=X_k, i=1,2,...,N, k=1,2,...i-1,i+1,...N \tag{5}$$

$$x_{i,j}^{new,P_1}=\begin{cases}x_{i,j}+r(p_{i,j}-I_{x_{i,j}}), F_{P_i}<F_i\\ x_{i,j}+r(x_{i,j}-p_{x_{i,j}}), F_{P_i}\geq F_i\end{cases} \tag{6}$$

$$X_i=\begin{cases}X_i^{new,P_1}, F_i^{new,P_1}<F_i\\ X_i, F_i^{new,P_1}\geq F_i\end{cases} \tag{7}$$

在公式 (5) 中，P_i 表示 $i-th$ 苍鹰瞄准的猎物位置，而 X_k 表示 $k-th$ 苍鹰在种群中的位置。这里，N 表示种群总规模，k 是从区间 $[1,N]$ 中随机选取的整数索引。

关于公式 (6)，$x_{i,\ j}$ 和 $x^{new,\ i}{}^{P1}{}_{,\ j}$ 分别表示 $i-th$ 苍鹰在 $j-th$维度上的当前位置和更新后的位置。F_{P_i} 和 F_i 表示与猎物位置以及 $i-th$ 苍鹰当前位置相关的目标函数值（适应度）。参数 r 是一个在范围 $[0,1]$, 内均匀分布的随机标量，而 I 是一个取值为 1 或 2 的随机整数参数。

最后，在公式（7）中，$X^{new,\ i}{}^{P1}$表示所提出的苍鹰新位置，$F^{new,\ i}{}^{P1}$对应其更新后的适应度值。该算法采用贪婪选择机制，仅当新位置能够改善目标函数值时才予以接受。

2）阶段2：追逐与逃逸（开发）：在第二阶段，一旦猎物在被锁定后试图逃跑，北方苍鹰便会发起高速追击，最终捕获猎物。这种开发行为以当前位置附近的局部搜索为特征，如图2的示意图所示。该阶段的数学模型由公式（8）至（10）定义：

$$x_{i,j}^{new,P_2} = x_{i,j} + R(2 \times r - 1)x_{i,j} \tag{8}$$

$$R = 0.02 \times (1 - \frac{t}{T}) \tag{9}$$

$$X_i = \begin{cases} X_i^{new,P_2}, F_i^{new,P_2} < F_i \\ X_i, F_i^{new,P_2} \geq F_i \end{cases} \tag{10}$$

在这些方程中，$x^{new,P_2}_{i,j}$ 表示北方苍鹰在追逐与逃逸阶段的 $j-th$ 维中新提出的坐标。因此，X^{new,P_2}_i 表示北方苍鹰的更新后位置向量，而 F^{new,P_2}_i 对应其所得的目标函数值。

参数 R 表示开发邻域的半径，该半径会随着仿真进程动态减小。具体而言，t 表示当前迭代次数，而 T 表示允许的最大迭代次数。这个随时间变化的半径 R 使算法在接近全局最优解时，能够从范围较广的局部搜索逐步过渡到精细收敛。

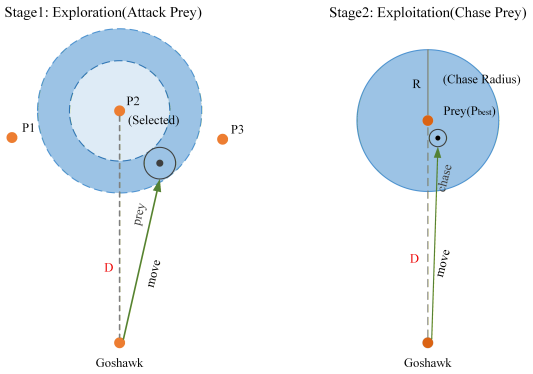

图2. NGO算法探索与追逐阶段示意图

III. 改进的北方苍鹰优化算法（INGO）

尽管与其他几种群体智能元启发式算法相比，标准NGO算法表现出更优的收敛性能，但仍容易陷入局部极值 [28]。为克服这一局限并进一步提升无线传感器网络的覆盖性能，我们提出了改进北方苍鹰优化算法（INGO）。INGO框架引入了两种协同策略：

- 多样化混沌映射初始化：该策略用于初始化种群，从而显著提高种群多样性并扩大初始搜索范围。
- 双向种群进化动力学：采用这一新策略，帮助算法摆脱局部最优，从而更深入地探索全局最优解。

INGO算法的主要目标是有效提升无线传感器网络的覆盖效率和网络连通性，为大规模传感器部署难题提供稳健的方法。

A. 通过多样化混沌映射初始化策略（*DCMIS*）进行初始化

在标准NGO算法中，初始种群通常由一次性伪随机函数生成。经验表明，这种随机方法常会导致解空间中的个体出现“聚集”，使算法从次优起点开始搜索，进而削弱全局探索和局部开发能力 [29]。为解决这一问题，INGO算法采用多样化混沌映射初始化策略（DCMIS）。该策略通过交替耦合 Logistic [30]映射和 Sine [31] 映射，生成具有低相关性和高遍历性的混沌序列。这确保初始个体均匀分布于整个可行域，从而提高搜索起点的多样性和覆盖范围。

DCMIS 的数学公式见公式 (11) 至 (13)：

$$z_{seed} = rand(N, dim) \tag{11}$$

$$z = sin(\pi \times (z_{seed}) \times (1 - z_{seed}) + sin(\pi \times z_{seed}))) \tag{12}$$

$$X = Lowerbound + |z| \times (Upperbound - Lowerbound) \tag{13}$$

在公式 (11) 中，z_{seed} 表示大小为 $N \times dim$ 的随机种子矩阵，是混沌序列的基础输入，其中 N 表示种群大小。

公式 (12) 表示 Logistic映射与正弦映射的结合。该公式以 Logistic映射为基础，通过引入额外的复杂性和非线性进行扩展，其中 z 表示对 z_{seed} 应用这些复杂的非线性变换后得到的输出混沌值矩阵。

最后，在公式（13）中，X 表示包含种群最终初始位置的矩阵。虽然多变量混沌映射生成的值看似随机，但它们能够以更高的均匀性有效覆盖搜索空间。这将产生高质量且多样化的初始种群，为算法后续的优化阶段奠定更稳健的基础。

B. 双向种群进化动力学（*BPED*）

为帮助NGO算法在迭代中后期摆脱局部最优，并增强种群活力，在追逐与逃逸阶段之后融入双向种群进化动力学（BPED）策略。

BPED策略主要受自然系统中观察到的帕累托原则（二八法则）启发。具体而言，该策略保留适应度值最高的前20%个体，并对其施加受控的自然变异，在探索邻近区域的同时保持精英特征。该过程的数学机制详见公式（14）至（17）：

$$w = \frac{1}{2} \times (\sin(2\pi \times freq \times t + \pi)\pi \times (\frac{t}{T_{max}}) + 1) \quad (14)$$

$$freq = \frac{1}{dim} \quad (15)$$

$$z = \sin(\pi \times (z_{rand} \times (1 - z_{rand}) + \sin(\pi \times z_{rand}))) \quad (16)$$

$$X_{good,new} = X_q + w \times (x_{best} - round(1 + z) \times X_k) \quad (17)$$

在这些公式中， w 表示用于调节搜索行为的动态权重因子。在算法初期， w 提供稳定的权重，以促进算法稳步收敛至目标区域。在后期， w 引入随机振荡以增强种群多样性，从而使算法能够避免局部停滞。

此外， t表示当前迭代次数， T_{max} 表示最大迭代次数，dim表示优化问题的维度。术语freq定义振荡频率，而 z 表示由随机种子 z_{rand}经非线性变换得到的混沌扰动。所得向量$X_{good,\ new}$ 表示精英个体的更新后的位置，该位置由全局最优位置 x_{best} 和随机选取的个体X_k 引导，以保持进化动量。

在公式（16）中， z 表示混沌扰动值。利用混沌遍历性，该参数能够生成更有效的扰动，从而促进对搜索空间的全面探索。不同于标准rand函数，后者尽管长期呈均匀分布，但在有限次迭代期间可能出现聚集值或重复值， z_{rand} 在此被用作专用随机种子，以确保所生成序列具有更高的独立性和非周期性。

公式 (17) 定义了“精英个体”的更新后的位置，记为 $X_{good,\ new}$，表示为下一次迭代计算出的目标坐标。该机制由以下部分构成：

基准向量(X_q)：表示随机选取的精英个体 q 的位置，作为当前更新的基本参考。

全局引导（x_{best}）：这表示全局最优位置——即截至目前由整个种群找到的适应度最高的个体——它对X_q 施加吸引力，使其朝已知的全局目标移动。

混沌策略切换（$round$（$1+z$））：由混沌值 z控制，该项充当随机算子，产生取值为1或2的离散值。它为更新过程引入非线性缩放。

排斥向量（X_k）：通过从 x_{best}中减去另一随机选定的精英个体 k的位置（或其两倍位置），该策略在更新方向中引入排斥分量。这可以防止种群盲目地向单一点（ x_{best}）收敛，从而增强探索能力，并有效避免早熟收敛。

BPED策略的第二个组成部分针对剩余20%的种群，这些个体被定义为“非精英”个体。这些智能体被认为停滞在解空间中缺乏成效的区域内。为防止算法在这些次优解上浪费计算资源，实施了强制重新探索机制，以发掘新的可能性。具体而言，根据随机阈值对这些个体应用随机双路径更新：

- 情况1：基于动态边界的局部细化（rand¡0.5）在第一种情况下，停滞个体会转化为新的探索型智能体，在当前全局最优解 x_{best}附近执行细粒度搜索。该过程的数学表达如下：

$$X_{bad,new} = x_{best} + \text{sign}(\text{rand} - 0.5) \times (lb_{ap} + \text{rand} \times (ub_{ap} - lb_{ap})) \quad (18)$$

在公式（18）中，$X_{bad,\ new}$ 表示非精英个体的更新后的位置。项 $sign(rand - 0.5)$充当方向扰动向量。值得注意的是， ub_{ap}和 lb_{ap} 表示动态边界，随着迭代次数 t 的增加而逐渐收窄，从而推动搜索逐步转向更具针对性的开发。

- 情况 2：大尺度随机变异（$rand \geq 0.5$）在其余 50% 的情况下，算法会执行激进的随机变异，推动个体前往搜索空间中完全未经探索的区域。这一机制对于摆脱持续存在的局部最优至关重要：

$$X_{bad,new} = X_{z1} - 2 \times \text{sign}(\text{rand} - 0.5) \times (lb + \text{rand} \times (ub - lb)) \quad (19)$$

在公式（19）中， X_{z1} 表示当前目标非精英个体的坐标，而 ub 和 lb 分别表示搜索

空间的全局上下界。乘数 $2 \times sign(rand - 0.5)$ 作为放大的扰动向量，确保变异步长足够大，从而使智能体脱离当前的次优吸引域。

C. INGO算法在无线传感器网络覆盖中的实现

所提出的INGO算法集成到无线传感器网络覆盖优化模型中的流程如图3所示：

算法1 改进北方苍鹰优化（INGO） 输入： f_{obj}（目标函数）， lb， ub， N， T输出： x_{best} （全局最优解）， Cov （最优覆盖率） 1：初始化：根据式（11）–（13），采用DCMIS策略生成种群 X 2：评估初始适应度并确定全局最优解 x_{best} 3：对于 $t = 1$ 到 T，执行 4：// 阶段一：标准北方苍鹰优化元启发式算法 5：对于 $i = 1$ 到 N，执行 6：探索：识别猎物并根据式（5）–（6）发起突袭 7：开发：根据式（8）–（9）执行追逐与逃逸追捕 8：更新：根据式（7）和（10），对位置 X_i进行贪心选择 9：结束循环 10：// 阶段二：双向种群进化（BPED） 11：对 X 排序，并划分为 X_{elite} （前20%）和$X_{non\text{-}elite}$ （后20%） 12： X_{elite} 进化：利用式（ 14 ） –（ 16 ）中的 w 和 z，根据式（17）更新 X_{elite} 13：重新探索 $X_{non\text{-}elite}$： 14：对于每个 $x \in X_{non\text{-}elite}$，执行 15：如果rand < 0.5，则 16：根据式（ 18 ）进行具有动态边界的局部搜索 17：否则 18：根据式（19）进行大尺度随机变异 19：结束条件判断 20：结束循环 21：更新 x_{best}、 f_{best}和 $Convergence\ curve(t)$ 22：结束循环 23：返回 x_{best}、 $Convergence\ curve$

–

–

步骤 1：模型构建与参数初始化。通过定义关键网络参数来建立无线传感器网络覆盖优化框架，包括监测区域的尺寸（$L \times M$）、传感器节点总数（N）、感知半径（R）、通信半径（R_c）以及网格点的离散化粒度。

步骤 2：通过 DCMIS 进行种群初始化。使用 DCMIS 生成苍鹰的初始种群。此步骤确保初始智能体具有较高的多样性，且在搜索空间中均匀分布，为全局探索奠定稳固的基础。

步骤 3：标准 NGO 迭代阶段。执行主要迭代循环，搜索智能体通过模拟北方苍鹰的捕食行为更新位置。该阶段包括全局探索（猎物识别与攻击）和局部开发（追逐与逃逸）。

步骤 4：通过 BPED策略增强优化。完成标准 NGO 更新后，调用 BPED。根据适应度对种群进行排序，其中排名前 20% 的精英个体朝全局最优位置演化，以提高精度；排名后 20% 的停滞个体则进行随机变异或重新初始化，以避开局部最优。

步骤5：收敛与性能评估。满足终止准则后，提取最优解向量，以确定传感器节点的最终坐标。随后，通过目标函数计算网络覆盖率。最后，生成收敛曲线和节点部署布局，以验证优化效果。

基于 INGO 的无线传感器网络覆盖优化完整流程图如图3所示，具体执行步骤总结于算法1中。

IV. 实验结果与讨论

为验证所提出的 INGO算法的有效性及其在无线传感器网络覆盖模型中的优化性能，开展了两类实验：消融研究，用于验证各个策略组件的作用；网络性能实验，用于评估该算法在实际无线传感器网络场景中的应用。所有仿真均在 Windows 10 平台上使用 MATLAB R2024a 环境完成。

A. 改进算法的对比测试

为系统分析所提出的 DCMIS 和 BPED 策略的有效性，设计了消融研究，详见表1。该比较评估了每项改进带来的增量性能提升。

为全面评估该算法的收敛性和鲁棒性，选取了15个基准测试函数（如表2所示）。为减小随机变化的影响，每种算法均独立运行20次，最大迭代次数上限为500。记录并汇总了包括最佳得分、平均得分和标准差在内的性能指标，结果见表3。

1）消融研究结果分析：表3所示的实验结果表明，提出的两种增强策略——DCMIS和BPED——均显著提升了算法的优化性能，且二者具有高度互补性。

DCMIS 初始化策略有效增强了该算法的全局探索能力。这一点

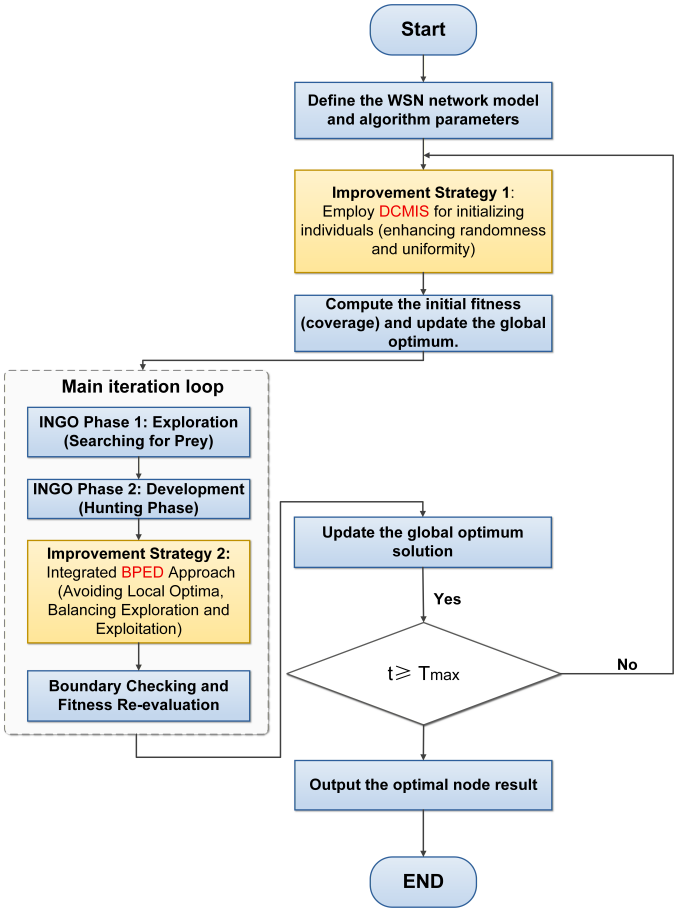

图 3. INGO-WSN 无线传感器网络覆盖总体流程图

表 I 策略验证消融研究设计。

算法	DCMIS	BPED	验证目的
NGO	×	×	整体评估的基线。
INGO-DCMIS	✓	×	评估初始解质量和全局遍历性。
INGO-BPED	×	✓	评估局部最优规避能力和准确性。
INGO	✓	✓	验证了两种策略的协同效应。

在 F_2 和 F_8 等函数中尤为明显，INGO-DCMIS 找到的最优解显著优于原始 NGO 算法的结果。然而，单独使用该策略时，在 F_6 和 F_{12} 等函数上会产生相对较高的标准差，这表明该策略虽然拓宽了搜索范围，但可能会对优化过程的稳定性略有影响。

相比之下，BPED策略在提升局部开发能力和增强算法鲁棒性方面发挥着关键作用。对于包括 F_3、 F_4、 F_6、 F_{12}和 F_{13}在内的多个复杂多峰函数，融入BPED不仅将收敛精度提升了

表 II 15 个基准测试函数的数学定义。

Name	函数表达式	Dim	范围
F_1	$\sum_{i=1}^{n} x_i^2$	30	$[-30, 30]$
F_2	$\sum_{i=1}^{n} \lvert x_i \rvert + \prod_{i=1}^{n} \lvert x_i \rvert$	30	$[-10, 10]$
F_3	$\sum_{i=1}^{n} (\sum_{j=1}^{i} x_j)^2$	30	$[-100, 100]$
F_4	最大值$_i\{\lvert x_i \rvert, 1 \le i \le n\}$	30	$[-100, 100]$
F_5	$\sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]$
F_6	$\sum_{i=1}^{n} (\lfloor x_i + 0.5 \rfloor)^2$	30	$[-100, 100]$
F_7	$\sum_{i=1}^{n} i x_i^4 + \text{rand}(0,1)$	30	$[-1.28, 1.28]$
F_8	$\sum_{i=1}^{n} -x_i \sin(\sqrt{\lvert x_i \rvert})$	30	$[-500, 500]$
F_9	$\sum_{i=1}^{n} [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$
F_{10}	$-20\exp(-0.2\sqrt{\frac{1}{n}\sum x_i^2}) - \exp(\frac{1}{n}\sum\cos(2\pi x_i)) + 20 + e$	30	$[-32, 32]$
F_{11}	$\frac{1}{4000}\sum x_i^2 - \prod\cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$
F_{12}	$\frac{\pi}{n}\{10\sin^2(\pi y_1) + \sum(y_i - 1)^2[1 + 10\sin^2(\pi y_{i+1})] + (y_n - 1)^2\} + \sum u(x_i, 10, 100, 4)$	30	$[-50, 50]$
F_{13}	$0.1\{\sin^2(3\pi x_1) + \sum(x_i - 1)^2[1 + \sin^2(3\pi x_{i+1})] + (x_n - 1)^2[1 + \sin^2(2\pi x_n)]\} + \sum u(x_i, 5, 100, 4)$	30	$[-50, 50]$
F_{14}	$(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^{2}(x_i - a_{ij})^6})^{-1}$	2	$[-65, 65]$
F_{15}	$\sum_{i=1}^{11} [a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2$	4	$[-5, 5]$

几个数量级，还显著降低了优化结果的标准差。这证明，精英引导和停滞个体重初始化机制能够成功帮助算法规避局部最优，同时保持种群多样性。

通过综合运用这两种策略，INGO算法在绝大多数测试函数上实现了最优的综合性能。值得注意的是，对于 F_9、 F_{12}和 F_{15}等函数，INGO始终保持卓越的收敛精度，同时具备最高的稳定性。这种协同作用表明，DCMIS与BPED的协同效应有效平衡了探索与开发之间的权衡。

2）通过箱线图分布进行统计分析：图4展示了五种竞争算法在多次独立试验中获得的适应度值的箱线图分布。对这些分布进行比较分析，可以得出关于每种方法的优化性能和鲁棒性的若干重要见解：

标准NGO算法的箱线图在所有组中垂直跨度（长度）最大，整体位置也最高。这表明其优化精度相对较低、鲁棒性较差，因为适应度值的方差较大，且收敛效果不理想。

对于第二组（INGO-DCMIS），其仅采用了DCMIS初始化策略，与基准NGO相比，四分位距（IQR）明显更窄。这种收缩表明，DCMIS策略通过减少随机伪随机初始化通常带来的性能波动，显著提高了算法的稳定性。

在第三组（INGO-BPED）中，仅引入BPED

表 III INGO 及其变体在基准函数上的消融结果。

函数	指标	NGO	INGO-DCMIS	INGO-BPED	INGO
F_1	Mean	1.27e-87	2.99e-87	1.94e-82	4.22e-82
	Std	1.87e-87	7.76e-87	4.29e-82	1.51e-81
F_2	Mean	1.35e-45	1.17e-45	4.64e-43	1.30e-43
	Std	1.89e-45	1.11e-45	1.27e-42	2.11e-43
F_3	Mean	1.48e-22	3.02e-23	4.52e-47	**4.93e-47**
	Std	5.66e-22	6.79e-23	2.09e-46	1.89e-46
F_4	Mean	2.06e-37	2.34e-37	1.25e-35	1.16e-35
	Std	2.09e-37	2.49e-37	2.15e-35	1.58e-35
F_5	Mean	25.9655	25.9506	25.5573	**25.5184**
	Std	0.4854	0.4327	0.8491	0.7869
F_6	Mean	6.41e-04	0.0012	9.17e-07	1.95e-06
	Std	0.0017	0.0044	3.81e-07	5.13e-06
F_7	Mean	6.18e-04	7.16e-04	3.21e-04	**2.83e-04**
	Std	2.48e-04	2.66e-04	1.45e-04	1.69e-04
F_8	Mean	-7.48e+03	-7.61e+03	-7.53e+03	-7.48e+03
	Std	385.1854	465.8406	707.7623	835.0605
F_9	Mean	**0**	**0**	3.74e-07	7.60e-11
	Std	0	0	2.05e-06	2.43e-10
F_{10}	Mean	6.01e-15	6.01e-15	1.63e-15	1.98e-15
	Std	1.79e-15	1.79e-15	1.70e-15	1.79e-15
F_{11}	Mean	**0**	**0**	**0**	**0**
	Std	0	0	0	0
F_{12}	Mean	6.91e-06	5.93e-05	7.47e-08	**6.81e-08**
	Std	1.24e-05	2.40e-04	2.96e-08	3.23e-08
F_{13}	Mean	0.2542	0.2355	0.0187	0.0195
	Std	0.1984	0.2148	0.0294	0.0264
F_{14}	Mean	0.9980	0.9980	0.9980	0.9980
	Std	0	4.12e-17	0	5.83e-17
F_{15}	Mean	3.08e-04	3.08e-04	4.60e-04	**3.07e-04**
	Std	3.39e-07	2.96e-07	3.47e-04	1.47e-19

策略时，可以观察到箱线图的中位线显著下移。这种下移表明搜索精度得到了大幅提升，证实BPED策略能够有效促进跳出局部最优，并缓解后期收敛阶段局部极值处的停滞。

最后一组代表同时采用 DCMIS 和 BPED 策略的完整INGO算法，其箱线图最为紧凑，且位于最低适应度水平。分布底部呈现为一条紧密的水平线段，表明同时整合这两种策略，使算法能够在所有试验中保持出色的收敛精度，同时确保卓越的稳定性和较强的鲁棒性。

B. 无线传感器网络覆盖优化性能与分析

为全面评估所提出的INGO算法的性能，针对四种 prominent 优化元启发式算法开展了对比研究：标准NGO算法 [22], 人工蜂群算法（ABC） [23], 改进野马优化器（IWHO）和萤火虫算法（FA） [24]。

为确保统计可靠性并减轻随机波动的影响，每种算法均进行了 30 次独立试验。利用这些试验的平均性能指标评估各方法在无线传感器网络覆盖优化中的效果。网络覆盖率采用式（4）中定义的目标函数 Cov进行量化。所有仿真参数，包括部署区域的尺寸和传感器配置，均按照表 4 所列设置进行了统一。

表 IV 无线传感器网络覆盖优化的仿真参数。

参数名称	数值
监测区域尺寸（$L \times M$）	50 m × 50 m
传感器节点总数（N）	35
感知半径（R）	5 m
通信半径（R_c）	10 m
离散化粒度（Δ）	0.8
最大迭代次数（T_{max}）	500
种群规模	30
独立实验运行次数	30

1）无线传感器网络部署与覆盖统计讨论：五种竞争算法生成的节点分布图如图5所示。对这些空间布局进行比较分析可得以下结论：

INGO算法产生的节点分布明显更加均匀。不同于标准NGO的随机初始化，DCMIS策略的引入确保传感器节点从一开始就均匀分散在整个监测区域内，有效消除了初始部署不平衡。相比之下，ABC算法的感知圆存在大量重叠（冗余度较高），并留下了多个未覆盖的“盲区”，尤其是在外围边界附近。尽管NGO和IWHO算法实现了较广泛的覆盖，但其分布模式缺乏INGO所展现的精确性和优化间距。

覆盖率直方图所展示的统计性能进一步量化了所提方法的优越性。INGO算法的峰值覆盖率达到92.81%，显著优于其他竞争性元启发式算法。基准NGO的覆盖率仅为85.19%，表明其在搜索后期难以跳出局部最优。BPED策略的融入使INGO能够避免此类停滞，找到更深层次的最优解，并使种群摆脱局部极值。尽管萤火虫算法取得了91.31%的可观覆盖率，但仍比INGO低1.5%。值得注意的是，INGO相比ABC算法的75.18%提升了17.63%，进一步验证了所提改进方法在复杂无线传感器网络优化任务中的强大竞争力和鲁棒性。

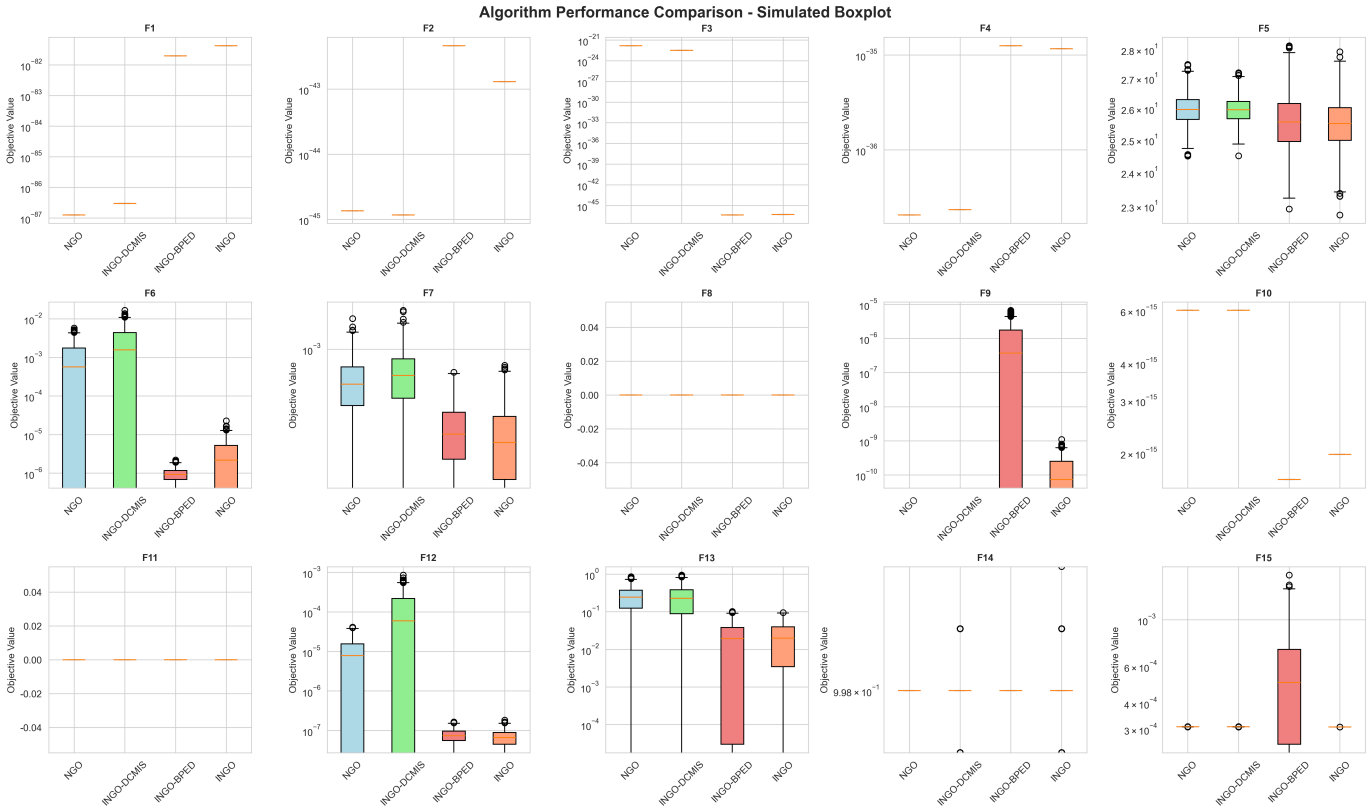

图 4. 算法性能比较——模拟箱线图

图

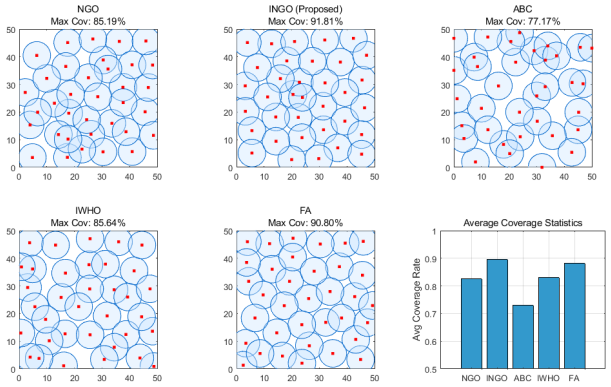

图 5. 无线传感器网络覆盖

2）收敛性分析与计算效率：图6展示了五种竞争算法的收敛特性。INGO的收敛曲线在初始迭代阶段快速上升。这充分凸显了DCMIS策略的有效性，该策略增强了初始种群的随机性和均匀性。通过提供高质量的初始分布，DCMIS使算法能够快速定位搜索空间中具有潜力的区域，从而有效缓解NGO及其他基准方法采用标准伪随机初始化时所存在的搜索盲目性。

在前 200 次迭代中，NGO、ABC 和 IWHO 的曲线逐渐趋于平缓，表明这些传统算法已陷入局部最优而停滞不前。相比之下，INGO 曲线则保持稳步上升。这种持续进展归功于 BPED策略，它使算法能够突破局部最优陷阱，并继续探索以获得更高的适应度值。

迭代次数约为 300 次时，INGO 曲线开始趋于平缓，最终稳定在 92.81% 的峰值覆盖率。与其他启发式算法相比，ABC 存在严重的早熟收敛问题；而 FA 虽然达到了相对较高的精度，但其初始搜索速度明显慢于 INGO。IWHO 的最终覆盖性能也不及所提出的方法。

结果表明，INGO算法不仅具有优异的覆盖性能，还具备出色的搜索效率和强大的全局优化能力。

表5汇总的无线传感器网络覆盖率对比结果进一步验证了所提出算法的显著优势。INGO算法取得了91.90%的突出平均覆盖率，表现出明显领先于其他竞争方法的优势。具体而言，与萤火虫算法（88.30%）、IWHO（82.66%）以及基准NGO（82.51%）的均值相比，该算法均实现了显著提升。这些数据表明，DCMIS和BPED策略的融合有效增强了该

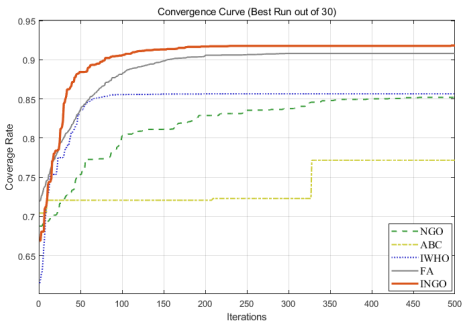

图 6. 收敛曲线

算法逃离局部陷阱并规避早熟收敛的能力。

从标准差这一指标来看，基准NGO算法的方差最低。然而，尽管其波动极小，但其较低的平均覆盖率（82.51 %）表明存在“低水平停滞”现象。这说明原始NGO在早期迭代中容易陷入局部极值，且缺乏进一步改进其解的探索能力。虽然INGO的标准差略高于NGO（差异仅为0.0014，可忽略不计），但其性能波动始终处于87%至93%的高覆盖率区间。这是一种有益的探索形式：即使算法逐渐逼近理论全局最优解，仍能保持适度的种群活力，以修正细微误差。

因此，INGO算法仅牺牲了微不足道的稳定性，便实现了覆盖性能的根本性跃升。它成功实现了高水平的动态平衡，确保无线传感器网络部署具有卓越的精度和可靠的优化结果。

表 V 不同算法的无线传感器网络覆盖性能统计比较。

算法	Best	最差 bɲu	平均值	标准差
NGO	85.19%	80.88%	82.51%	0.01088
INGO	**92.81%**	**87.10%**	**91.90%**	0.01223
ABC	75.18%	71.68%	72.54%	0.01261
IWHO	84.76%	80.68%	82.66%	0.01420
FA	91.31%	85.94%	88.30%	0.01231

C. 连通性可靠性分析

为评估无线传感器网络模型的通信可靠性，采用连通率（η_{conn}）作为主要指标。网络被建模为无向图 $G = (S, E)$，其中 S 是传感器节点集合，E 是边集合。如果两个节点之间的欧几里得距离小于通信半径 R_c，则它们之间存在一条边。令 $C = \{C_1, C_2, \ldots, C_m\}$ 表示图 G中的连通分量集合，使得每个 C_k 都是一个节点的互相连通子集，且 $\bigcup_{k=1}^{m} C_k = S$。连通率 η_{conn} 定义为最大连通分量中的节点数与节点总数 N之比，公式如下：

$$\eta_{conn} = \frac{\max_k |C_k|}{N} \times 100\% \tag{20}$$

其中，$|C_k|$ 表示 $k-th$连通分量中的节点数，$max_k|C_k|$ 表示网络中最大连通子图的规模。

竞争算法生成的通信拓扑如图7所示。从网络拓扑的角度来看，INGO算法构建了最完整、最均匀的通信结构。结果表明，NGO、IWHO和FA算法均存在孤立节点，从而导致局部通信链路断裂。相比之下，INGO算法实现了100.00%的完全连通，形成了分布均匀且规则的网状拓扑。这表明，所提出的算法在最大化覆盖区域的同时，能够有效防止节点孤立，从而确保整个网络通信的可靠性和鲁棒性。

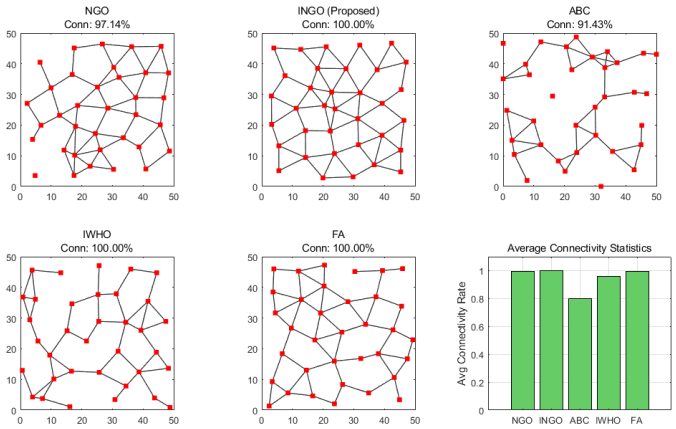

图7. 算法连通性网络结构

1）网络连通性统计分析：对多次独立运行中连通率的统计直方图进行评估，以进一步考察生成的网络拓扑的稳定性。INGO算法对应的柱形达到最大可能值，其平均连通率始终保持在峰值 100.00%。这些结果表明，该算法的稳定性显著优于其他竞争元启发式算法。

ABC算法虽然偶尔能够实现完全连通，但其平均连通率最低（约为75%）。这种显著波动表明，经过ABC优化的网络很容易发生碎片化和拓扑断连。

总体而言，INGO算法成功地在覆盖最大化与通信链路维护之间实现了最优平衡。INGO被证明是一种稳健的

解，适用于感知范围和数据传输可靠性都至关重要的实际无线传感器网络部署。

V. 结论

本文针对无线传感器网络覆盖优化这一关键挑战，提出了一种融合多策略的改进北方苍鹰优化（INGO）算法。通过引入多样化混沌映射初始化策略（DCMIS），该算法生成的初始种群相比随机方法具有更高的质量和更均匀的空间分布；同时，双向种群进化动力学（BPED）的引入使算法能够有效规避早熟收敛并跳出局部最优。该策略成功平衡了全局探索与局部开发，从而显著提高了收敛效率。

全面的仿真实验表明，所提出的INGO算法在各项关键性能指标上始终优于多种代表性元启发式算法（NGO、ABC、IWHO和萤火虫算法），具体而言，其峰值覆盖率达到92.81%，并保持100.00%的网络连通性。这些结果验证了所提出改进措施在优化无线传感器网络节点部署方面的有效性和优越性。

未来的研究将着重于将 INGO 算法拓展至更复杂的现实场景。这包括解决三维空间部署、动态移动节点调度和能源效率平衡问题，以进一步验证该算法在多样且受限环境中的普适性和鲁棒性。

致谢

参考文献

[1] S. P. Racharla 和 K. Jeyaraj，“一种利用基于适应度的混合启发式算法实现无线传感器网络能源感知节点定位的鲁棒方法”，《国际通信系统期刊》，第 38 卷，第 2 期，第 e6079 页，2025 年。[2] J. Amutha、S. Sharma 和 J. Nagar，“基于传感器、部署、感知模型、覆盖和能源效率的 WSN 策略：综述、方法与待解决问题”，《无线个人通信》，第 111 卷，第 2 期，第 1089–1115 页，2020年。[3] K. Gulati、R. S. K. Boddu、D. Kapila、S. L. Bangare、N. Chandnani 和 G. Saravanan，“物联网（IoT）中的无线传感器网络技术综述”，《今日材料：会议录》，第 51 卷，第 161–165 页，2022年。[4] Y. Y. Ghadi、T. Mazhar、T. Al Shloul、T. Shahzad、U. A. Salaria、A. Ahmed 和 H. Hamam，“无线传感器网络安全的机器学习解决方案：综述”，《*IEEE Access*》，第 12 卷，第 12 699–12 719 页，2024年。[5] R. Jia 和 H. Zhang，“面向能源高效无线传感器网络节点覆盖的无线传感器网络（WSN）模型”，《*IEEE Access*》，第 12 卷，第 27 596–27 610 页，2024年。[6] D. Samiayya、J. Daniel 和 A. Chandrasekar，“用于安全可靠无线传感器网络的模糊信任型混合莱维蛇优化”，《国际通信系统期刊》，第 38 卷，第 17 期，第 e70264 页，2025 年。[7] J. Tang、G. Liu 和 Q. Pan，“用于求解优化问题的代表性群体智能算法综述：应用与趋势”，《*IEEE/CAA* 自动化学报》，第 8 卷，第 10 期，第 1627–1643 页，2021年。

[8] W. Li、G.-G. Wang 和 A. H. Gandomi，《基于学习的智能优化算法综述》。《计算工程方法档案》，第28卷第5期，2021年。[9] X. Wang、H. Hu、Y. Liang 和 L. Zhou，《群智能优化算法的数学模型及应用》。《计算工程方法档案》，第29卷第6期，第3815–3842页，2022年。[10] M. Toloueiashtian、M. Golsorkhtabaramiri 和 S. Y. B. Rad，《一种用于解决无线传感器网络点覆盖问题的改进鲸鱼优化算法》。《电信系统》，第79卷第3期，第417–436页，2022年。[11] J. Akram、H. S. Munawar、A. Z. Kouzani 和 M. P. Mahmud，《使用自适应传感器实现无线传感器网络中的优化目标覆盖》。《传感器》，第22卷第3期，文章编号1083，2022年。[12] Y. Ou、F. Qin、K.-Q. Zhou、P.-F. Yin、L.-P. Mo 和 A. Mohd Zain，《一种采用多策略覆盖的无线传感器网络改进灰狼优化器》。《对称性》，第16卷第3期，文章编号286，2024年。[13] L. Cao、Y. Yue、Y. Cai 和 Y. Zhang，《一种基于连通性和可靠性的异构无线传感器网络新型覆盖优化策略》。《IEEE Access》，第9卷，第18 424–18 442页，2021年。[14] A. B. Alnajjar、A. M. Kadim、R. A. Jaber、N. A. Hasan、E. Q. Ahmed、M. S. M. Altaei 和 A. L. Khalaf，《使用遗传算法优化无线传感器网络》。《机器人与控制期刊》（JRC），第3卷第6期，第827–835页，2022年。[15] R. Yarinezhad 和 S. N. Hashemi，《一种用于无线传感器网络目标覆盖问题的传感器部署方法》。《环境智能与人性化计算期刊》，第14卷第5期，第5941–5956页，2023年。[16] M. Elhoseny、A. Tharwat、X. Yuan 和 A. E. Hassanien，《移动无线传感器网络的k覆盖优化》。《应用专家系统》，第92卷，第142–153页，2018年。[17] T. G. Nguyen、C. So-In、N. G. Nguyen 和 S. Phoemphon，《一种具有区域覆盖感知能力的新型无线传感器网络节能聚类协议》。《对等网络与应用》，第10卷第3期，第519–536页，2017年。[18] M. Dehghani、˘S. Hub´alovsk`y 和 P. Trojovsk`y，《北方苍鹰优化：一种用于解决优化问题的新型基于群体的算法》。《IEEE Access》，第9卷，第162 059–162 080页，2021年。[19] Y. Liang、X. Hu、G. Hu 和 W. Dou，《一种增强型北方苍鹰优化算法及其在实际优化问题中的应用》。《数学》，第10卷第22期，文章编号4383，2022年。[20] H. T. Sadeeq 和 A. M. Abdulazeez，《用于全局优化的改进北方苍鹰优化算法》，载于《2022年第4届国际先进科学与工程会议（ICOASE）》。IEEE，2022年，第89–94页。[21] L. Zeng、M. Hu、C. Zhang、Q. Yuan 和 S. Wang，《一种用于全局优化和工程设计的多策略改进北方苍鹰优化算法》。《计算机、材料与连续介质》，第80卷第1期，2024年。[22] O. I. Khalaf、G. M. Abdulsahib 和 B. M. Sabbar，《使用蜜蜂算法优化无线传感器网络覆盖》。《信息科学与工程期刊》，第36卷第2期，第377–386页，2020年。[23] C. Zeng、T. Qin、W. Tan、C. Lin、Z. Zhu、J. Yang 和 S. Yuan，《基于改进野马优化器的异构无线传感器网络覆盖优化》。《仿生学》，第8卷，70，2023 1，第。页。。[24] W. Liu、P. Li、Z. Ye 和 S. Yang，《一种基于萤火虫算法的无线传感器网络节点部署优化方法》，载于《2021年IEEE第4届先进信息与通信技术国际会议（AICT）》。IEEE，2021年，第167–170页。[25] S. S. Kagi 和 S. V. Mallapur，《改进海狮算法的无线传感器网络覆盖》。《国际通信系统期刊》，第37卷第18期，文章编号e5953，2024年。[26] K. Subburathinam、V. Bakthavatchalam、R. K. C. Pandian 和 K. M. Subramaniam，《使用混合灰狼优化-和声搜索算法增强无线传感器网络的连通性和覆盖》。《国际通信系统期刊》，第37卷第14期，文章编号e5858，2024年。[27] P. Jangir、A. E. Ezugwu、K. Saleem、Arpita、S. P. Agrawal、S. B. Pandya、A. Parmar、G. Gulothungan 和 L. Abualigah，《一种用于质子交换膜燃料电池参数估计的混合变异北方苍鹰与精英反向学习人工兔优化器》。《科学报告》，第14卷第1期，文章编号28657，2024年。

[28] X. Wang, 《一种用于解决优化问题的强化型北方苍鹰优化算法》, *Engineering Research Express*, 第6卷第4期, 文章编号045267, 2024年。[29] P. D. Kusuma 和 F. C. Hasibuan, 《最佳-最差北方苍鹰优化器：一种新的随机优化方法》。*International Journal of Electrical &Computer Engineering (2088-8708)*, 第13卷第6期, 2023年。[30] S. M. Basha、P. Mathivanan 和 A. B. Ganesh, 《使用逻辑-正弦-帐篷-切比雪夫（LSTC）映射进行位级彩色图像加密》, *Optik*, 第259卷, 文章编号168956, 2022年。[31] Q. Wu, 《用于产生混沌的级联正弦混沌化模型》, 非线性动力学, 第106卷第3期, 第2607–2620页, 2021年。