

文章编号: 2095-4980(2024)11-1244-09

基于 CoMOPSO 的传感器优化部署方法

张玉翔, 郭兰图, 刘玉超

(中国电波传播研究所, 山东 青岛 266075)

摘要: 传感器优化部署问题是一个涉及传感器覆盖效果、用频冲突概率以及资源利用的多目标优化问题。现有的传感器优化部署方法大多采用加权方式, 将多个优化目标转换为单目标进行求解。这种方法不仅依赖先验知识, 还会导致最优解的多样性损失。对此, 提出一种协同进化多目标粒子群优化(CoMOPSO)算法。设计了一种协同进化框架, 通过收敛种群保证高维问题的收敛性, 进而快速接近帕累托最优前沿; 多样性种群使用 ϵ -支配方法保证全局和局部最优解集的完整和多样性; 最后采用快速非支配排序和精英个体保留策略提高解的质量。实验结果表明, 对于传感器优化部署问题, 该方法的反世代距离(IGD)和 M_3^* 指标均优于传统优化算法, 具有更好的收敛性和多样性, 能有效提高传感器网络性能。

关键词: 传感器; 优化部署; 多目标优化; 粒子群; 协同进化

中图分类号: TN914.42

文献标志码: A

doi: 10.11805/TKYDA2023383

A sensor optimization deployment method based on Collaborative evolution Multi-Objective Particle Swarm Optimization

ZHANG Yuxiang, GUO Lantu, LIU Yuchao

(China Research Institute of Radiowave Propagation, Qingdao Shandong 266075, China)

Abstract: The sensor optimization deployment is a multi-objective optimization problem involving sensor coverage effectiveness, frequency conflict probability, and resource utilization. The existing sensor optimization deployment methods mostly adopt weighted approaches to transform multiple optimization objectives into a single objective problem for resolution, which not only relies on prior knowledge but also leads to the loss of diversity in optimal solutions. To address these issues, a Collaborative evolution Multi-Objective Particle Swarm Optimization(CoMOPSO) algorithm is proposed. It designs a collaborative evolution framework that guarantees the convergence of high-dimensional problems through the convergence of the population, and rapidly approaches the Pareto optimal frontier. The diverse population uses the ϵ -dominance method to ensure the integrity and diversity of the global and local optimal solution sets. A fast non-dominated sorting and elite individual preservation strategy is employed to enhance the quality of solutions. Experimental results demonstrate that, for the sensor optimization deployment problem, the proposed method outperforms traditional optimization algorithms in terms of Inverted Generational Distance(IGD) and M_3^* indicators, exhibiting better convergence and diversity and effectively improving the performance of sensor networks.

Keywords: sensor; optimization deployment; multi-objective optimization; particle swarm; collaborative evolution

近年来, 随着传感器技术的迅速发展和无人机的广泛应用, 由无人机携带传感器载荷组成的无线传感器网络在交通监控、场景分析和战场侦察等领域引发了广泛关注^[1-3]。无人机集群的机动性使传感器的部署不再受地形限制^[4], 充分发挥了多传感器网络的空间多样性。目标区域的预警探测是传感器网络的关键应用之一, 但存在几个关键问题: 首先, 在传感器数量有限的情况下, 如何选择合适的部署位置, 使传感器网络的探测覆盖面积

收稿日期: 2023-11-20; 修回日期: 2023-12-19

基金项目: 国家自然科学基金资助项目(U20B2038)

最大^[5]；在可用频段有限的情况下，需考虑如何选择传感器所用的频段以及无人机之间的通信频段^[6]，以确保传感器的预警探测功能正常运行且能够实时传递信息；最后，鉴于传感器数量和能源有限的约束，还需要解决如何选择开机时间以最小化传感器网络资源的使用^[7]。寻找一系列符合以上需求的优化部署方案是一项具有实际应用意义的多目标优化问题。

当无线传感器网络监测区域时，覆盖尽可能多的区域以确保可靠性至关重要。覆盖率可定义为描述传感器覆盖区域程度的指标^[8]。为进一步优化覆盖性能，文献[7]提出了一种基于萤火虫算法的传感器覆盖优化算法；文献[9]则考虑了无线传感器网络的覆盖区域及工作时长，解决在保证工作时长情况下的覆盖问题；文献[10-11]更进一步考虑了传感器网络的最大覆盖和连通性的双重问题。这些研究基于通信距离对连通性做出了假设，在保证传感器互联的情况下寻找最大覆盖方案。但在实际的无线传感器网络中，预警探测和通信都依赖于电磁波的发射和接收，因此频率冲突和用频功率问题也需要纳入考虑。为解决这一问题，文献[12]将博弈论的纳什均衡概念与 Pareto 最优相结合，解决移动网络中的频率分配问题。此外，还有研究着眼于提高频谱利用率和降低频率冲突，将其作为双目标进行优化，使用多目标优化算法求解频率分配问题^[13]。多目标问题通常具有多个约束，而且是非线性非凸问题，因此传统的搜索方法不太适用。为解决这类问题，通常采用启发式搜索算法。求解多目标问题有两种主要方法：一种是将多个目标函数以权重系数累加、 ϵ -约束等方式转换为单目标问题，然后进行求解^[14-15]。这种方式只能得到一个最优解，并且由于权重与主要目标的选择依赖于先验知识，容易导致结果不理想；另一种方法是多目标进化算法，如 NSGA(Non-dominated Sorting Genetic Algorithm)^[16]，MOEA(Multi-Objective Evolutionary Algorithm)^[17]，MOPSO(Multi-Objective Particle Swarm Optimization)^[18]等算法，这些算法不需要将多目标转换为单目标，因此最终的结果是得到每个优化目标各有优劣的多个较优解。这种方法可以帮助克服单目标方法的限制，同时提供更多关于不同权衡方案的信息。

目前对于传感器网络的多目标优化部署问题，大都转换为单目标问题求解，这种方法不仅依赖先验知识，而且由于单次求解权重的单一性，只能求得一组解，得不到潜在的其他可行解。多目标进化算法在解决多目标传感器优化这类高维问题时，容易因为收敛过快导致最优解分布不均，丧失多样性。本文针对多目标传感器网络部署问题，综合考虑传感器网络的覆盖效果、用频冲突概率和资源使用情况，提出一种协同进化多目标粒子群(CoMOPSO)算法，该算法通过引入基于 ϵ -支配的多样性种群，解决算法早熟收敛、局部最优的问题。与其他算法相比，该算法的优化结果更优越。

1 问题模型

1.1 传感器优化部署问题描述

传感器优化部署问题可描述为多个异构传感器在目标区域通过特定阵位选择及用频、功率选择，实现目标区域覆盖面积最大、用频冲突最小及资源使用最少。本文的传感器部署场景基本假设如下：

- 1) 传感器为有源传感器，通过发射电磁波并接收回波进行预警探测；
- 2) 传感器之间通过无线通信系统进行信息交互；
- 3) 传感器可用频段之间存在重叠。

问题模型如图 1 所示，目标预警区域为一个 300 km×300 km 的区域 A，传感器网络由 5 个探测能力不同的全向无线传感器组成，可部署在 150 km×150 km 的区域 B 内。每部传感器位置坐标为 (x,y) ，探测使用频率为 f ，探测功率为 P ，通信使用频率为 f_c 。

1.1.1 区域覆盖率定义

有源传感器通过主动发射电磁波，接收物体表面反射的电磁波实现探测。为对目标区域进行探测，传感器网络需尽可能地覆盖整个目标区域，使用区域覆盖率刻画该性能。假设在目标监测区域 S 内， S_i 为第 i 个传感器的探测区域， N 为传感器网络中的传感器数量， S_m 为任务空间区域，则区域覆盖率 F_{cov} 可表述为：所有传感器探测区域的并集与任务空间的交集得到的结果与任务空间区域的比例：

$$F_{cov} = [(\cup_{i=1}^N S_i) \cap S_m] / S_m \quad (1)$$

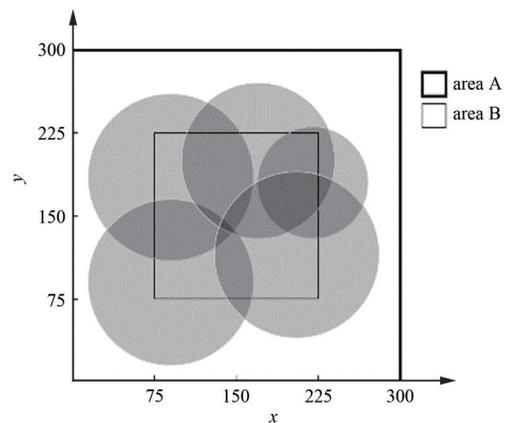


Fig.1 Schematic of the problem model of the sensor deployment

图1 传感器部署问题模型示意图

式中 $F_{\text{cov}} \in [0, 1]$, F_{cov} 越接近于 1, 探测效果越好。

1.1.2 用频冲突分析

在预警探测过程中, 多个传感器的探测或通信使用相同频率工作时, 会发生冲突, 导致探测效果降低或通信失效。当二者功率量级相差较大时, 使用相邻频率也会出现类似问题。为避免这种情况的发生, 在可用频段允许的情况下, 需尽量避免使用相同频段甚至相邻频段。

本文将电磁互扰因素分类为上述的同频干扰、邻频干扰, 对这两种通常存在的主要干扰类型分别建立相应的干扰约束矩阵, 用矩阵中的元素值表示其行和列所对应的设备间的干扰关系(此处的设备包含传感器的探测以及通信设备), 由此得到了同频干扰、邻频干扰的约束矩阵 \mathbf{A} 、 \mathbf{B} 。假设同频约束矩阵 \mathbf{A} 中某元素 $a_{ij}=1$, 则表示设备 i 和 j 存在同频干扰; 反之, $a_{ij}=0$, 则表示设备 i 和 j 不会产生干扰。

设 α 、 β 分别为同频干扰、邻频干扰的惩罚因子, 即各种干扰的加权值。将各种干扰的约束条件综合起来得到频率冲突代价:

$$F_{\text{fc}} = \alpha \sum_{i=1}^N \sum_{j=i+1}^N A_{ij} + \beta \sum_{i=1}^N \sum_{j=i+1}^N B_{ij} \quad (2)$$

$$A_{ij} = \begin{cases} a_{ij}, & f(i) = f(j) \text{ and } i \neq j \\ 0, & \text{others} \end{cases} \quad (3)$$

$$B_{ij} = \begin{cases} b_{ij}, & |f(i) - f(j)| < k \text{ and } i \neq j \text{ and } \frac{P_i}{P_j} > 20 \text{ dB} \\ 0, & \text{others} \end{cases} \quad (4)$$

此时 F_{fc} 越大, 表明集群中冲突发生得越多, 用频效能越差。

1.1.3 资源使用模型

预警过程中, 目标区域的大小不同, 因此并不需要所有传感器同时以最大功率开机。在决策过程中, 针对不同场景下的覆盖范围需求, 传感器可以以部分开机甚至不开机的方式达到降低用频冲突几率, 保证战前隐蔽性的效果。同时, 由于无线传感器单次布置所携带的能源有限, 为延长传感器网络的工作时长, 功率应尽量小。假设预警过程的总时长为 T , 第 n 个传感器的功率为 P_n , 第 n 个传感器以 P_n 功率开机的时长为 t_n , 用阶段功率描述传感器网络在阶段中的能量消耗速度, 追求资源使用速率的最小化。资源使用情况表示为:

$$F_{\text{re}} = \sum_{n=1}^N \frac{P_n t_n}{T} \quad (5)$$

1.2 传感器部署问题的数学模型

根据上述描述, 综合考虑传感器的覆盖面积、用频冲突、资源使用, 建立探测器优化部署模型。优化目标函数为:

$$\min f_1 = 1 - F_{\text{cov}} = 1 - [(\cup_{i=1}^N S_i) \cap S_m] / S_m \quad (6)$$

$$\min f_2 = F_{\text{fc}} = \alpha \sum_{i=1}^N \sum_{j=i+1}^N A_{ij} + \beta \sum_{i=1}^N \sum_{j=i+1}^N B_{ij} \quad (7)$$

$$\min f_3 = F_{\text{re}} = \sum_{n=1}^N \frac{P_n t_n}{T} \quad (8)$$

优化约束为:

$$\text{s.t.} \begin{cases} P_{\min, n} < P_n < P_{\max, n} \\ f_{\min, n} < f_n < f_{\max, n} \\ L_n \in L \\ f_{C, \min, n} < f_{C, n} < f_{C, \max, n} \end{cases} \quad (9)$$

式中: P_n 为第 $n(n \in [1, N])$ 个传感器的功率, $P_{\max, n}$ 和 $P_{\min, n}$ 分别为对应传感器功率的最大和最小值; f_n 为第 n 个传感器探测所用频率, $f_{\max, n}$ 和 $f_{\min, n}$ 分别为对应传感器探测频率的上限、下限; L_n 为第 n 个传感器部署的位置, L 为可部署区域; $f_{C, n}$ 为第 n 个传感器所用的通信频率, $f_{C, \max, n}$ 和 $f_{C, \min, n}$ 分别为该传感器通信可用频率的上限、下限。

2 算法描述

2.1 多目标优化

本文建立的优化模型是有约束的多目标优化问题，该类问题的求解比单目标问题更加复杂，需要同时优化几个目标。多目标问题通常可表示为：

$$\begin{cases} \min F(x) = [f_1(x), f_2(x), \dots, f_n(x)] \\ \text{s.t. } g_i(x) \geq 0, i \in [1, G]; h_j(x) = 0, j \in [1, H] \end{cases} \quad (10)$$

式中： $g_i(x) \geq 0$ 与 $h_j(x) = 0$ 分别为 x 的约束条件； G 与 H 分别为两种约束的数量。

多目标优化问题具有多个互相影响甚至冲突的目标函数，因此以求得单个目标为最优解的方案并不能同时使其他目标为最优值。此类问题所求的最优解不再是单个解，而是 Pareto 最优解集。多目标优化问题的 Pareto 解是由可行域中所有的“非支配解”组成的。为提高多目标进化算法求解的多样性，文献[19]提出了“ ϵ -支配”概念，“ ϵ -支配”是 Pareto 支配关系的弱化，定义如下：

定义 1 ϵ -支配：取 $\epsilon \in (0, 1)$ ， x_0 “ ϵ -支配” $x_1(x_0 \rightarrow_{\epsilon} x_1)$ ，当且仅当 $(1-\epsilon)f_i(x_0) \leq f_i(x_1), i=1, 2, \dots, M$ 。

定义 2 ϵ -近似 Pareto 解集：取 $\epsilon \in (0, 1)$ ，如果 F 中的任意解 g 都能被 F_{ϵ} 中至少一个解 f “ ϵ -支配”，则称 F_{ϵ} 为 F 的 ϵ -近似 Pareto 解集，即： $\forall g \in F; \exists f \in F_{\epsilon}$ 使得 $f \rightarrow_{\epsilon} g$ 。

图 2 以双目标优化问题为例，描述了“ ϵ -支配”在目标空间的分布情况，Pareto 的实线与虚线之间的区域是 ϵ -近似 Pareto 解集的取值范围。

2.2 CoMOPSO 算法

多目标优化算法在解决传感器优化部署问题时，其核心任务在于获取分布尽可能均匀的 Pareto 解集，但在实际算法应用中，如何平衡算法决策空间的收敛性与多样性是一个难以克服的挑战。这是因为过度追求解的多样性可能会影响算法的收敛速度，如果算法的收敛速度过快，可能会导致解集局限于部分解空间，引发多样性不足的问题。为应对这一挑战，受 TIAN YE 等^[20]的启发，本文提出一种 CoMOPSO 算法。该算法利用 2 个种群协同工作，在多目标优化中实现收敛性与多样性的平衡。具体而言，协同进化算法包括 2 个种群：收敛种群和多样性种群。在决策空间中，收敛种群采用多目标粒子群算法的本身收敛策略，致力于寻找真实的 Pareto 解集；多样性种群则运用“ ϵ -支配”概念进行迭代，保障解的多样性。在算法的迭代过程中，这 2 个种群之间通过信息交换实现种群的协同发展。

2.2.1 协同进化框架

多目标传感器优化部署问题是多优化变量的高维问题，具有搜索空间维度高、状态空间大的特点，因此种群中数量有限的个体容易因分布不均而使算法陷入局部最优。本文选用协同进化框架，将其用于多目标粒子群算法，在算法中使用收敛种群和多样性种群协同优化。种群初始化后，分别按照多目标粒子群算法的更新方式产生新的子代，之后采用不同的策略更新收敛种群与多样性种群，在保证算法收敛性的情况下增强算法的多样性，避免局部最优。该算法示意图如图 3 所示。具体而言，收敛种群使用非支配排序与精英保留策略进行种群的筛选，保证算法中收敛良好的解能够引导算法向 Pareto 前沿收敛；多样性种群使用基于“ ϵ -支配”的方式更新种群，通过种群中分布良好的解提高解的多样性。代码逻辑如表 1 所示。

2.2.2 多目标粒子群算法的种群更新原理

多目标粒子群算法的种群更新基于粒子向个体历史最优 p_{best} 及全局最优 g_{best} 的移动。种群更新过程中，粒子在保持自身运动惯性的基础上依据一定的运算规则更新自己的位置和速度信息，速度的更新公式为：

$$v_{ij}(t+1) = wv_{ij}(t) + c_1r_1[p_{p_{best},j} - x_{ij}(t)] + c_2r_2[p_{g_{best},j} - x_{ij}(t)] \quad (11)$$

式中： w 为惯性权重； c_1 和 c_2 为 2 个最优值的学习因子，称为加速系数； r_1 和 r_2 为(0,1)内均匀分布的随机值。

位置的更新公式为：

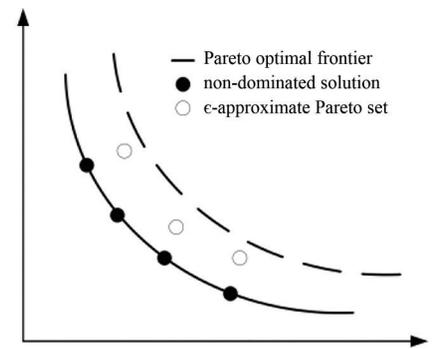


Fig.2 Relation between Pareto frontier and ϵ -approximate Pareto solution set

图 2 Pareto 前沿与 ϵ -近似 Pareto 解集的关系

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1), j = 1, 2, \dots, d \tag{12}$$

式中 d 为粒子的空间维数。

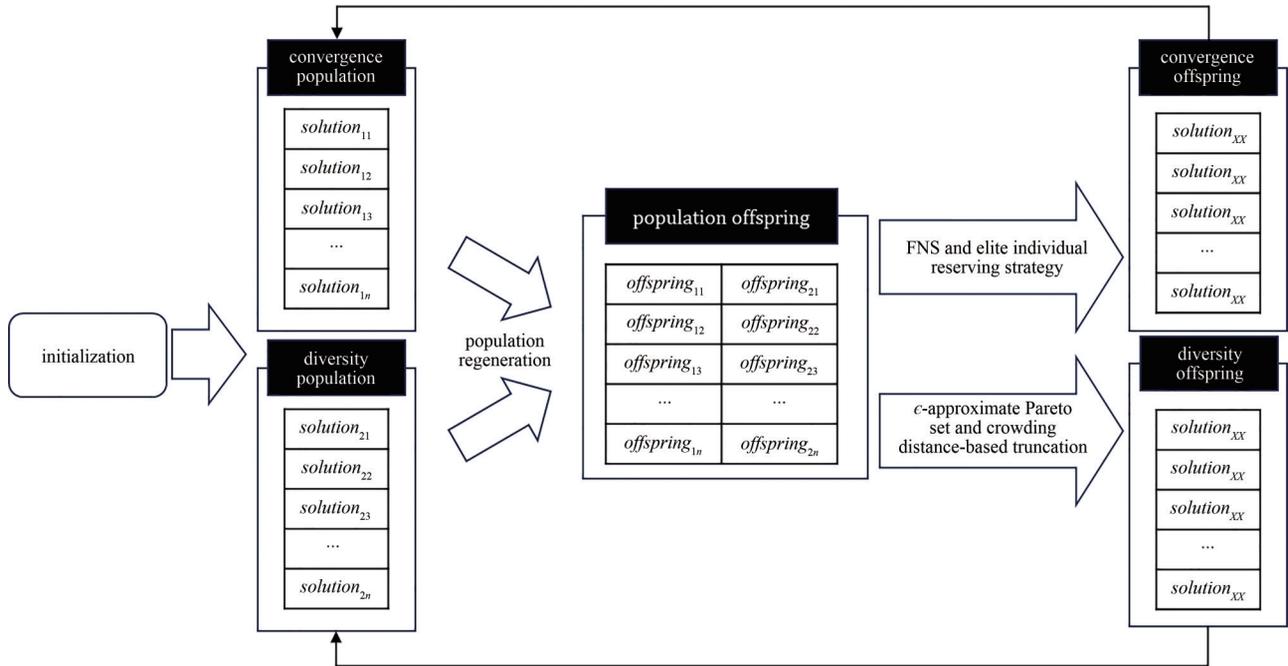


Fig.3 Coevolutionary framework
图3 协同进化框架

表1 协同进化多目标粒子群算法框架

Table1 Framework of collaborative evolution multi-objective particle swarm algorithm

algorithm 1: framework of collaborative evolution multi-objective particle swarm algorithm
input: maximum number of iterations Max G , population size N , ϵ
output: external archive of the diverse population DP : Archive DP
1 Random initialization CP
2 Random initialization DP
3 Function $C \leftarrow$ Function(CP) /* Compute the objective function for each solution in the population */
4 Function $D \leftarrow$ Function(DP)
5 for x in Max G
6 $NCP \leftarrow CP$ /* Population update, produce offspring and update Archive CP */
7 $NDP \leftarrow DP$
8 [CP , Function C] \leftarrow $NCP+NDP$ /*Environmental selection*/
9 [DP , Function D] \leftarrow $NCP+NDP$
10 end

惯性权重 w 可以控制粒子在收敛特性和探索特性之间的均衡。本文传感器优化部署问题涉及高维度和广泛的搜索空间，因此在算法的早期阶段需要强大的全局搜索能力以充分探索决策空间；在后期需要较小的惯性权重控制粒子的收敛。传统的固定惯性权重难以适应不同迭代阶段的全局和局部搜索需求，为此，本文采用基于正态分布衰减的动态惯性权重^[21]，平衡优化过程中的全局探索和局部搜索能力。这种动态惯性权重确保在优化的早期阶段具备强大的全局探索能力，随着迭代次数的增加，逐渐在全局和局部搜索能力之间取得平衡，并在后期最大化局部搜索能力。动态变化的 w 引导算法避免陷入局部最优的同时保证了收敛速度。动态惯性权重的正态分布衰减为：

$$w = w_{\min} + (w_{\max} - w_{\min}) \frac{1}{\sqrt{2\pi} \theta} e^{-\frac{(t/t_{\max})^2}{2\theta^2}} \tag{13}$$

式中： t_{\max} 为最大迭代次数； t 为当前迭代次数； θ 取 0.443 3； w 取值 0.4~0.9。

加速系数 c_1 和 c_2 表示向个体历史最优及全局最优移动的权重： c_1 较大时，粒子倾向于根据各自历史经验搜

索，有利于避免陷入局部最优，但会导致种群过度分散在解空间中，不利于算法收敛； c_2 较大时，粒子倾向于根据种群的全局最优寻找最优解，容易过早陷入局部最优。鉴于固定加速系数无法平衡全局搜索能力与算法收敛速度，本文引入自适应加速系数^[22]。这一策略鼓励算法在迭代的早期更加注重解的多样性，随着迭代的进行，逐渐增强了局部搜索的能力，并精细调节全局最优解的精确度，提高算法的收敛速度。自适应系数如式(14)~(15)所示：

$$c_1 = 0.5(c_{\max} - c_{\min}) \left(\frac{t}{t_{\max}} \right)^2 + c_{\min} \tag{14}$$

$$c_2 = (c_{\max} - c_{\min}) \left(\frac{t}{t_{\max}} \right)^2 + c_{\max} \tag{15}$$

2.2.3 快速非支配排序(Fast Non-dominated Sorting, FNS)方法

不同于单目标优化算法中可以直接使用目标函数大小作为适应度对解的优劣进行评估，多目标优化算法需同时考虑多个目标函数，在种群的环境选择中，需使用FNS方法对个体进行评价，如表2所示。

表2 快速非支配排序算法

Table2 Fast Non-dominated Sorting algorithm

algorithm 2:FNS method
input: population size N , population NA, objective function
output: the levels of each solution in the population
/* All individuals are compared with each other, and the number of times each individual is dominated is recorded n_x */
1 for x in N
2 for y in N
3 if (x is dominated by y) n_x+1
4 $np_{\max} = \max(n_x) \ x \in N$
5 All individuals are divided into $np_{\max} + 1$ levels, that is, $0 - np_{\max}$ levels
6 Returns NA and its corresponding level

2.2.4 收敛种群的环境选择

考虑到传感器优化部署问题优化变量多，状态空间庞大，算法不易收敛，本文选用协同进化框架中的一个种群为算法提供收敛性知识。收敛种群使用快速非支配排序法作为策略，为多样性种群提供收敛知识，推动算法快速接近 Pareto 前沿。对收敛种群及多样性种群的子代联合种群进行排序，如果非支配解的数量小于种群规模，取非支配排序靠前的粒子补充规模形成新种群；如果非支配解数量大于种群规模，通过精英个体保留策略取其中的前 N 个解作为新种群。代码逻辑如表3所示。

2.2.5 多样性种群的环境选择

表3 收敛种群环境选择算法

Table3 Convergent population environmental selection algorithm

algorithm 3: convergent population environment selection
input: population size N , convergent population CP , convergent population objective function Function C , offspring NCP and NDP
output: the new convergent population CP , and its objective function Function C
1 $TCP \leftarrow NCP \cup NDP$ /*Total convergent population*/
2 $ND \leftarrow \text{FNS}(TCP) < 1$ /*The fast non-dominated sorting method is adopted to obtain the current Pareto optimal frontier PF*/
3 if $\text{Num}(ND) < N$ then
4 $FDX \leftarrow \text{sort}(\text{Function } TC, \text{FNS})$ /*Non-dominated sorting population*/
5 $CP \leftarrow ND + FDX(\text{Num}(ND):N)$
6 else
7 $CDX \leftarrow \text{SortbyCrowd}(ND, N)$ /* Based on the elite individual retention strategy, the first N of ND are selected as the new population */
8 $CP \leftarrow CDX(\text{Num}(ND):N)$
9 end if
10 Function $C \leftarrow \text{Function}(CP)$

由于传感器优化部署问题的解空间较大，算法求解过程中容易因种群的分布不均导致解集多样性降低。本文通过多样性种群在更新过程中引入“ ϵ -支配”，将 Pareto 解集扩展到了 ϵ -近似 Pareto 集。通过这种方式筛选的种群不止包含 Pareto 前沿，还包含一些可接受的局部最优解，算法流程如表4所示。首先通过FNS方法寻找当前种群的 Pareto 前沿，而后通过“ ϵ -支配”寻找 ϵ -近似 Pareto 集，该集包括 Pareto 解集及“ ϵ -接受”的局部最优解。最后通过拥挤距离排序，取前 N 个个体作为新的种群。

表 4 多样性种群环境选择算法

Table 4 Diverse population environment selection algorithm

algorithm 4: diverse population environment selection	
input: population size N , diverse population DP , diverse population objective function Function D , convergent population objective function Function C , offspring NCP and NDP	
output: new diverse population DP , and its objective function Function D	
1	$TDP \leftarrow NCP \cup NDP$
2	$ND \leftarrow \text{FNS}(TDP) < 1$ /* The fast non-dominated sorting method is adopted to obtain the current Pareto optimal frontier PF */
3	$\epsilon_i \leftarrow \text{getepsn}(\epsilon, i)$ /* The ϵ_i of this iteration is calculated by the formula */
4	Find the ϵ -approximate Pareto set S
5	if $\text{Num}(S) < N$ then
6	$CDX \leftarrow \text{sort}(\text{Function } TC, \text{Crowd})$ /*Crowding degree sorting population*/
7	$DP \leftarrow ND + CDX(\text{Num}(ND):N)$
8	else
9	$DP \leftarrow CDX(\text{Num}(ND):N)$ /* Based on the elite individual retention strategy, the first N of ND are selected as the new population */
10	end if
11	Function $D \leftarrow \text{Function}(DP)$

3 实验仿真

3.1 实验设计

测试所提方法的性能。协同进化多目标粒子群算法和作为比较的算法均由 python3.6.13 编写，运行环境为 16 GB 内存、AMD Ryzen 5 5600H 的 6 核处理器。

将传感器参数范围作为算法约束，基于 1.1 节中提到的问题模型，求出传感器网络的覆盖面积、用频冲突、资源使用目标函数并使用算法优化，最终得到一系列传感器部署方案。本节仿真条件为：传感器网络目标预警区域为一个 $300 \text{ km} \times 300 \text{ km}$ 的方形区域 A ，部署区域为区域中心的 $150 \text{ km} \times 150 \text{ km}$ 区域 B ，传感器的可使用参数范围如表 5 所示。

表 5 传感器可使用的参数范围

Table 5 Available parameter settings for sensor

serial number	P_R/kW	f_R/GHz	f_C/GHz
1	410~2 100	1.4~1.7	1.40~1.45
2	15~130	1.2~1.6	1.40~1.45
3	15~130	1.2~1.6	1.40~1.45
4	15~130	1.2~1.6	1.40~1.45
5	200~660	1.3~1.5	1.40~1.45

多目标优化算法的性能指标如下：

1) 反世代距离(IGD)是一个综合评价指标，主要通过计算每个在真实 Pareto 前沿面上的点到算法获取的个体集合之间的最小距离和，评价算法的收敛性能和分布性能。值越小，表示算法的收敛性和多样性越好。

$$IGD = \sqrt{\frac{|Q|}{\sum_{i=1}^{|Q|} d_i^2}} \quad (16)$$

式中 $d_i = \min_{x \in S} \|F(q^i) - F(x)\|$, $q^i \in Q$ ，为 Pareto 近似前沿 Q 上的参考点 q 与最近的解 x 之间的欧氏距离。

2) 多样性指标 M_3^* 评估解集的分布延展性，计算解集 S 中在每个目标上相距最远的个体之间的距离和， M_3^* 越大，解集的多样性越好：

$$M_3^*(S) = \sqrt{\sum_{k=1}^m \max \|f_k(x^i) - f_k(x^j)\|} \quad (17)$$

3.2 实验结果与讨论

为评估 CoMOPSO 算法在解决多目标传感器网络部署问题的性能，选择经典多目标优化算法 MOPSO 与近年提出的多目标萤火虫算法(Multi-Objective Firefly Algorithm, MOFA)^[23]进行比较。针对场景中假设的条件，采用 3 种算法进行仿真计算，每个算法运行 10 次。测试算法在 1.2 节中传感器部署问题的数学模型中 3 个目标函数上的最优结果，如表 6 所示。

由表 6 可以看出，在求解多目标传感器网络部署问题时，CoMOPSO 的收敛精确度明显优于其他算法，表明 CoMOPSO 更稳定，陷入局部最优解的概率较低，能够更快地向最优解收敛。依据测试结果，计算 3 种算法的 IGD 和 M_3^* 指标的平均值与标准差，结果如表 7 和表 8 所示，IGD 和 M_3^* 的分布情况如图 4 所示。

从 IGD 的测试结果可以明显观察到，CoMOPSO 在所有指标中均取得了最佳的平均值，同时方差表现也极佳，且其最小值均来自于 CoMOPSO 的结果。因此可以认为，CoMOPSO 相较于其他算法，能获得更出色的 Pareto 解集，兼顾了收敛性和多样性且表现优异。从 M_3^* 的测试结果可以看出，CoMOPSO 算法大部分取得了最佳

平均值和最佳方差，表明 CoMOPSO 获得的 Pareto 解集在分布多样性方面表现出众。综合图 4 中 IGD 和 M_3^* 的分布情况，可以得出明显的结论：对于多目标传感器网络部署问题，CoMOPSO 算法在综合性能上明显优于 MOPSO 与 MOFA 算法。

表6 不同算法在3个目标函数上的最优结果对比

Table6 Comparison of the optimal results of different algorithms on three objective functions

algorithm	individual number	f_1	f_2	f_3
CoMOPSO	100	0.089 305	0.025 000	186.326 7
	200	0.086 328	0.022 222	173.755 1
	500	0.082 715	0.019 444	163.345 7
	1 000	0.075 866	0.011 111	180.808 9
MOPSO	100	0.09 529	0.026 389	193.568 9
	200	0.087 367	0.023 611	191.009 3
	500	0.083 425	0.019 444	187.810 1
	1 000	0.076 784	0.011 111	180.914 7
MOFA	100	0.134 488	0.029 167	198.670 3
	200	0.125 017	0.023 611	174.329 1
	500	0.125 168	0.022 222	168.506 4
	1 000	0.077 548	0.015 278	183.040 2

表7 不同算法的IGD结果对比

Table7 The test results of IGD by different algorithms

individual number	CoMOPSO		MOPSO		MOFA	
	average	standard deviation	average	standard deviation	average	standard deviation
100	4.299 167	1.999 636	6.173 314	4.946 319	9.250 628	4.431 110
200	6.425 465	4.612 899	13.418 090	7.824 349	7.108 353	2.757 939
500	5.064 104	2.527 729	5.676 850	3.706 507	10.169 400	9.167 093
1 000	2.206 621	2.735 404	2.580 854	3.871 063	2.467 515	2.904 374

表8 不同算法的 M_3^* 结果对比

Table8 The test results of M_3^* by different algorithms

individual number	CoMOPSO		MOPSO		MOFA	
	average	standard deviation	average	standard deviation	average	standard deviation
100	1.835 815	0.692 066	1.618 255	0.722 962	1.713 352	0.774 785
200	1.541 196	0.609 995	1.431 145	0.864 912	1.696 409	0.662 356
500	1.586 226	0.774 208	1.296 344	0.892 386	0.856 436	0.352 618
1 000	0.919 238	0.472 931	0.911 357	0.474 223	0.900 171	0.610 740

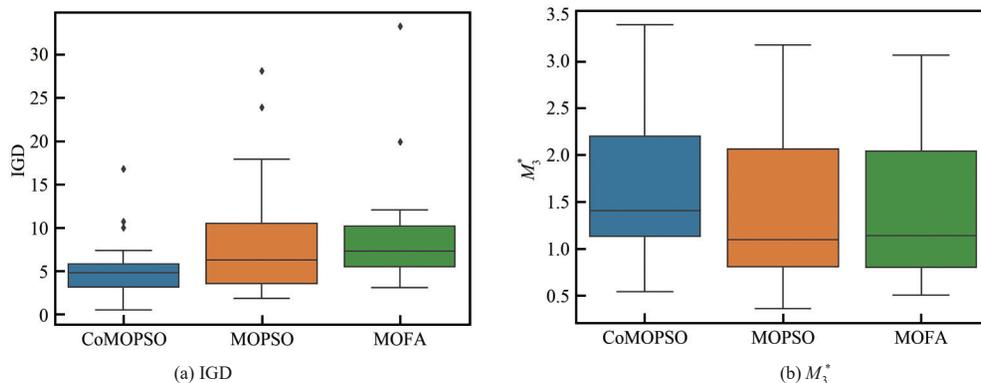


Fig.4 The boxplots for the test results of IGD and M_3^* by different algorithms

图4 不同算法IGD和 M_3^* 测试结果的箱线图

4 结论

本文提出了一种协同进化多目标粒子群算法，用于解决传感器优化部署问题。首先建立了传感器优化部署的多目标优化模型，然后基于多目标粒子群算法引入协同进化框架，将多目标粒子群算法与双种群的协同进化相结合，提高了算法的多样性。此外，采用精英个体保留策略，确保解的质量和最终的 Pareto 解集。实验结果明

确表明,相较于传统的 MOPSO 和 MOFA 算法,本文所提算法在解决传感器网络优化部署问题方面表现卓越。这一突出表现主要体现在算法更好的收敛性、多样性及更高质量的解集上。本文的工作为解决多目标传感器网络部署问题提供了一种有效可行的方法。

本研究在传感器网络部署问题上取得了显著成果,但仍有进一步研究的空间。未来的工作将侧重于完善异构传感器性能评价函数,处理目标区域变化的最佳传感器网络更新策略,以及将算法部署到分布式系统的潜在应用中。

参考文献:

- [1] MA Xianyong, DONG Zejiao, QUAN Weiwen, et al. Real-time assessment of asphalt pavement moduli and traffic loads using monitoring data from built-in sensors: optimal sensor placement and identification algorithm[J]. *Mechanical Systems and Signal Processing*, 2023, 187(1): 109930. doi:10.1016/j.ymssp.2022.109930.
- [2] LI R L, MEHR N, HOROWITZ R. Submodularity of optimal sensor placement for traffic networks[J]. *Transportation Research Part B: Methodological*, 2023, 171(1): 29–43. doi:10.1016/j.trb.2023.02.008.
- [3] 万佳庆, 王鹏飞, 郭强, 等. 基于烟花算法的要地防空多传感器部署规划方法[J]. *飞行力学*, 2021, 39(6): 62–67, 88. (WAN Jiaqing, WANG Pengfei, GUO Qiang, et al. Multi-sensor deployment planning method for air defense in strategic point based on firework algorithm[J]. *Flight Dynamics*, 2021, 39(6): 62–67, 88.)
- [4] XIE Jiapin, FU Qiyong, JIA Riheng, et al. Optimal energy and delay tradeoff in UAV-enabled wireless sensor networks[J]. *Drones*, 2023, 7(6): 368. doi:10.3390/drones7060368.
- [5] SEREDYŃSKI F, KULPA T, HOFFMANN R, et al. Coverage and lifetime optimization by self-optimizing sensor networks[J]. *Sensors*, 2023, 23(8): 3930. doi:10.3390/s23083930.
- [6] TAKYU O, SHIRAI K, FUJII T, et al. Adaptive channel assignment with predictions of sensor results and channel occupancy ratio in PhyC-SN[J]. *IEEE Access*, 2019, 7(1): 44645–44658. doi:10.1109/ACCESS.2019.2909525.
- [7] SANGWAN A, SINGH R P. Survey on coverage problems in wireless sensor networks[J]. *Wireless Personal Communications*, 2015, 80(4): 1475–1500. doi:10.1007/s11277-014-2094-3.
- [8] 董振平, 陈亚州, 于军琪, 等. 基于改进萤火虫算法的 WSN 覆盖优化[J]. *太赫兹科学与电子信息学报*, 2023, 21(2): 225–234. (DONG Zhenping, CHEN Yazhou, YU Junqi, et al. WSN coverage optimization based on Improved Firefly Algorithm[J]. *Journal of Terahertz Science and Electronic Information Technology*, 2023, 21(2): 225–234.) doi:10.11805/TKYDA2020537.
- [9] YARINEZHAD R, HASHEMI S N. A sensor deployment approach for target coverage problem in wireless sensor networks[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14(5): 5941–5956. doi:10.1007/s12652-020-02195-5.
- [10] TOSSA F, ABDU W, ANSARI K, et al. Area coverage maximization under connectivity constraint in wireless sensor networks[J]. *Sensors*, 2022, 22(5): 1712. doi:10.3390/s22051712.
- [11] LIU Zhixiong, ZHOU Wei. Energy-efficient algorithms for path coverage in sensor networks[J]. *Sensors*, 2023, 23(11): 5026. doi:10.3390/s23115026.
- [12] LAIDOUI F M B, SI-TAYEB F B, BENGHERBIA N, et al. Nash-Pareto genetic algorithm for the frequency assignment problem[J]. *Procedia Computer Science*, 2018(126): 282–291. doi:10.1016/j.procs.2018.07.262.
- [13] DAOUDI A, BENATCHBA K, BESEDIK M, et al. Performance assessment of biogeography-based multi-objective algorithm for frequency assignment problem[J]. *International Journal of Bio-Inspired Computation*, 2021, 18(4): 199–209. doi:10.1504/ijbic.2021.119981.
- [14] FERREIRA B, ANTUNES A, NELSON C, et al. Multi-objective optimization of pressure sensor location for burst detection and network calibration[J]. *Computers & Chemical Engineering: An International Journal of Computer Applications in Chemical Engineering*, 2022(162): 107826-2–10.
- [15] FAKHOURI A A, SOLTANI R. Multi-objective robust optimization for the traffic sensors location problem[J]. *IEEE Access*, 2021(9): 6225–6238. doi:10.1109/access.2020.3047045.
- [16] SRINIVAS N, DEB K. Multiobjective optimization using nondominated sorting in genetic algorithms[J]. *Evolutionary Computation*, 1994, 2(3): 221–248. doi:10.1162/evco.1994.2.3.221.
- [17] ZHANG Qingfu, LI Hui. MOEA/D: a Multiobjective Evolutionary Algorithm based on Decomposition[J]. *IEEE Transactions on Evolutionary Computation*, 2007, 11(6): 712–731. doi:10.1109/TEVC.2007.892759.
- [18] COELLO C A C, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(3): 256–279. doi:10.1109/TEVC.2004.826067.