

控制与决策

Control and Decision

基于自适应遗传学习粒子群算法的多无人机协同任务分配

张祥银, 夏爽, 张天

引用本文:

张祥银, 夏爽, 张天. 基于自适应遗传学习粒子群算法的多无人机协同任务分配[J]. 控制与决策, 2023, 38(11): 3103–3111.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0240>

您可能感兴趣的其他文章

Articles you may be interested in

[具有重组学习和混合变异的动态多种群粒子群优化算法](#)

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation

控制与决策. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

[面向多目标侦察任务的无人机航线规划](#)

UAV trajectory planning for multi-target reconnaissance missions

控制与决策. 2021, 36(5): 1191–1198 <https://doi.org/10.13195/j.kzyjc.2019.1284>

[基于滚动时域粒子群优化的视频去雾算法](#)

Receding horizon particle swarm optimization based video defogging algorithm

控制与决策. 2021, 36(9): 2218–2224 <https://doi.org/10.13195/j.kzyjc.2019.1183>

[基于R2指标和目标空间分解的高维多目标粒子群优化算法](#)

R2 indicator and objective space partition based many-objective particle swarm optimizer

控制与决策. 2021, 36(9): 2085–2094 <https://doi.org/10.13195/j.kzyjc.2020.0113>

[基于局部搜索的反向学习竞争粒子群优化算法](#)

Opposition-based learning competitive particle swarm optimizer with local search

控制与决策. 2021, 36(4): 779–789 <https://doi.org/10.13195/j.kzyjc.2019.1150>

基于自适应遗传学习粒子群算法的多无人机协同任务分配

张祥银^{1,2,3†}, 夏爽^{1,2}, 张天^{1,2}

(1. 北京工业大学 信息学部, 北京 100124; 2. 数字社区教育部工程中心, 北京 100124;
3. 北京工业大学 北京人工智能研究院, 北京 100124)

摘要: 研究救援场景下的多无人机协同任务分配问题, 考虑幸存者所需援助类型的不同, 建立更贴合实际的组合优化模型. 针对该模型, 提出一种自适应遗传学习粒子群算法 (adaptive genetic learning particle swarm optimization, AGLPSO). 首先, 根据无人机与幸存者之间的救援关系, 采用一种实向量编码机制处理决策变量约束, 以简化模型求解. 然后, 通过两层级联结构提高算法搜索能力: 第 1 层通过遗传学习策略生成高质量的精英粒子, 并对进化停滞的粒子采用精英学习策略进行更新, 以跳出局部最优; 第 2 层利用精英粒子指导种群的搜索方向, 并根据粒子群的进化速度和粒子的聚集程度, 采用自适应进化策略提高算法在不同进化时期的寻优能力. 仿真实验表明, 所提出的 AGLPSO 算法能快速、有效地找到合理的救援分配方案.

关键词: 协同任务分配; 粒子群算法; 实向量编码; 遗传学习; 精英学习; 自适应

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0240

引用格式: 张祥银, 夏爽, 张天. 基于自适应遗传学习粒子群算法的多无人机协同任务分配 [J]. 控制与决策, 2023, 38(11): 3103-3111.

Adaptive genetic learning particle swarm optimization based cooperative task allocation for multi-UAVs

ZHANG Xiang-yin^{1,2,3†}, XIA Shuang^{1,2}, ZHANG Tian^{1,2}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Engineering Research Centre of Digital Community of Ministry of Education, Beijing 100124, China; 3. Beijing Institute of Artificial Intelligence, Beijing University of Technology, Beijing 100124, China)

Abstract: The problem of cooperative task allocation for multi-UAVs in rescue scenarios is studied. Considering the different types of assistance required by survivors, a more practical combinatorial optimization model is established, and an adaptive genetic learning particle swarm optimization (AGLPSO) algorithm is proposed for this model. Firstly, according to the rescue relationship between UAVs and survivors, a real vector coding mechanism is adopted to deal with the constraints of decision variables to simplify the solution of the model. Then, the search ability of the algorithm is improved through the two cascading layers. In the first layer, the genetic learning strategy is used to generate elite particles with high quality, and the evolutionary stagnation particles are updated by the elite learning strategy to jump out of local optimum. In the second layer, the search direction of the population is guided by the elite particles, and according to the evolution speed of particle swarm and aggregation degree of particles, the adaptive evolution strategy is used to improve the searching ability of the algorithm in different evolutionary periods. The simulation results show that the proposed AGLPSO algorithm can quickly and effectively find a reasonable rescue allocation scheme.

Keywords: cooperative task allocation; particle swarm optimization; real vector coding; genetic learning; elite learning; adaptive

0 引言

面对日趋复杂的多样化任务需求, 单架无人机携带的资源和执行任务的能力有限, 难以独立完成. 多

无人机系统具有更灵活、容错性更高等优点, 能有效且高效地执行各种复杂任务. 然而, 如果多架无人机只是简单地组成集群, 没有良好的协同机制, 则不仅

收稿日期: 2022-02-11; 录用日期: 2022-06-24.

基金项目: 国家自然科学基金项目 (61703012); 北京市自然科学基金项目 (4182010).

责任编委: 侯忠生.

†通讯作者. E-mail: xy_zhang@bjut.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

不能提高无人机执行任务的效率,还可能由于系统规模的增大而带来严重的冲突和资源浪费.因此,在多约束的复杂环境下,对任务进行合理的分配是提高系统整体性能、实现多机协同的关键.

多无人机协同任务分配问题是指,将一个或一组成有序任务分配给无人机,并保证系统的总体收益达到最优^[1].文献[2-4]指出,该问题具有复杂度高、约束性强、计算难度大等特点,合理的问题建模和有效的求解算法对其处理至关重要.

在建模时,既要考虑到无人机的数量、异构性、执行任务的能力等因素,又要考虑到任务的类别、分配的环境及各种协同的约束条件.文献[5]面向真实战场环境,将各任务视为互相关联的整体,建立了考虑分配次序的任务分配模型;文献[6]针对无人机与任务的数量关系,建立了统一的任务分配模型;文献[7]考虑到目标的异质性,将目标划分为点目标、线目标和面目标,进而建立了扩展的多Dubins旅行商模型;文献[8]研究救援场景下的协同任务分配,考虑了最后救援时间约束,建立了最小化平均等待时间的任务分配模型.

人们为求解多无人机协同任务分配问题,采用了很多优秀的分配算法.文献[9]提出了一种可适应匈牙利算法的求解分配问题;文献[10]提出了一种基于协商法的分布式任务分配方法,在求解救援场景下的任务分配问题时获得了较好的效果;文献[11]提出了一种基于Q学习的快速任务分配算法,将在线计算转移到离线学习过程中,有效解决了存在环境不确定性的异构无人机任务分配问题.此外,文献[12]提出了一种基于潜在博弈的分布式算法,用于求解动态环境中的任务分配问题.近年来,群体智能算法因具有较强的鲁棒性和灵活的编码结构而被广泛应用于求解各种复杂问题^[13].粒子群优化(particle swarm optimization, PSO)算法作为最经典的群体智能算法之一,具有简单、易实现、收敛速度快等特点.因此,文献[14-15]将其应用于协同任务分配,取得了良好的分配效果;文献[16]提出了一种遗传学习粒子群算法,采用两层级联结构将遗传算法与粒子群有机结合,提高了算法全局搜索能力和搜索效率;文献[17]进一步采用环形拓扑结构,增强了种群的多样性和探索性.

尽管目前已有很多PSO方法用来解决多无人机协同任务分配问题,但在处理大规模救援场景下的多无人机协同任务分配时仍存在以下难点:1)建立符合实际问题的优化模型,文献[8,10,18]都假设幸存者只需要一种类型的援助,虽然简化了问题的复杂度,但忽略了救援时幸存者的实际需求;2)设计粒子

的编码和解码机制,表示无人机与幸存者间的救援关系,并降低问题的复杂度;3)增强粒子群的寻优能力,灵活控制不同情况下粒子群的收敛速度.

为解决这些难点,本文构建具有不同援助类型的幸存者救援模型,进而提出一种自适应遗传学习粒子群算法(adaptive genetic learning particle swarm optimization, AGLPSO)用于求解该模型.首先,设计一种实向量编码机制来表示无人机与幸存者之间的救援关系.然后,采用两层级联结构增强算法寻优能力:第1层根据遗传学习策略生成精英种群,用于指导粒子群的搜索方向,同时根据精英学习策略对进化停滞的精英粒子进行更新;第2层中粒子群根据自适应进化策略,动态调整惯性权重和学习因子,使种群可以根据实际搜索情况,灵活控制收敛速度.最后,通过仿真实验验证该算法能有效求解多无人机协同任务分配问题.

1 问题描述及建模

本文研究救援场景下的多无人机协同任务分配问题.该问题可具体描述为:分散于多个机场的 n 架不同类型无人机对 m 个分布在场景中不同位置的幸存者进行救援.其中,每个幸存者均需要不同数量、不同种类的物资援助.协同任务分配的目标是在满足各种实际约束的情况下,以较小的资源消耗尽快地救援尽可能多的幸存者.

设幸存者集合 $\mathbf{T} = \{T_1, T_2, \dots, T_m\}$,其中每个幸存者都需要一定数量的食物、药物援助,分别对应任务集合 $\mathbf{K} = \{1, 2\}$.无人机集合 $\mathbf{U} = \{U_1, U_2, \dots, U_n\}$,其中每架无人机均可携带不同数量的食物和药物以完成救援任务.对于每个幸存者,其食物和药物援助可由不同无人机完成.一般情况下,无人机的数量满足救援需求.定义 x_{ij}^k 为决策变量,表示无人机 U_i 与幸存者 T_j 之间的救援关系.当无人机 U_i 为幸存者 T_j 提供 k 类援助时, $x_{ij}^k = 1$;否则 $x_{ij}^k = 0$.

本文将平均等待时间和航程距离作为任务分配方案的评价指标,并采用罚函数的方法处理问题中存在的多种约束.由此,多无人机协同任务分配问题的数学模型可以表述为

$$\min F = \omega_1 \cdot f_1 + \omega_2 \cdot f_2 + \omega_3 \cdot \sum_{p=1}^P c_p. \quad (1)$$

其中: f_1 、 f_2 分别为平均等待时间和航程代价;第3项为罚函数方法处理约束所产生的惩罚项, c_p 表示违反对应约束的惩罚, P 为约束的总数量; ω_1 、 ω_2 、 ω_3 为权重系数,其设置取决于无人机的飞行速度、救援场景的大小和救援任务的规模.

1.1 平均等待时间代价函数

等待时间指无人机从机场出发到完成救援幸存者 T_j 所用的时间,这是评价救援快速性的关键因素. 平均等待时间代价函数为

$$f_1 = \frac{1}{m} \sum_{j=1}^m t_j. \quad (2)$$

其中: t_j 表示幸存者 T_j 的等待时间,由两种援助任务中最晚完成的一项决定,即

$$t_j = \max(t_j^1, t_j^2), \quad (3)$$

t_j^1 和 t_j^2 分别表示幸存者 T_j 食物援助和药物援助的完成时间.

1.2 航程代价函数

航程指无人机从机场出发到完成所有救援任务再返回机场的总飞行距离,这是评价救援过程中资源消耗的关键因素. 航程代价函数为

$$f_2 = \sum_{i=1}^n \text{Length}_i, \quad (4)$$

其中 Length_i 表示无人机 U_i 的航程.

1.3 协同约束函数

1.3.1 决策变量约束

一般幸存者的数量多于无人机的数量.为完成救援任务,要求无人机能救援所有幸存者,且每个幸存者的每类援助仅被无人机提供一次.有

$$\sum_{i=1}^n x_{ij}^k = 1, \quad \forall j = 1, 2, \dots, m, \quad \forall k = 1, 2. \quad (5)$$

1.3.2 最大航程约束

由于自身物理约束,每架无人机所能飞行的最大航程距离是有限的.为保证安全,要求无人机总飞行距离不能超过其自身限定的最大航程,即

$$\text{Length}_i \leq L_{i,\max}, \quad \forall i = 1, 2, \dots, n. \quad (6)$$

$$c_1 = \begin{cases} 0, & \text{Length}_i \leq L_{i,\max}; \\ 1, & \text{otherwise.} \end{cases} \quad (7)$$

其中: $L_{i,\max}$ 表示无人机 U_i 的最大飞行距离,式(7)表示不满足最大航程约束时所产生的惩罚.

1.3.3 最大负载约束

无人机所能携带的救援物资是有限的,它为幸存者所提供的援助数量不能超过其所携带的总数量,即

$$\sum_{j=1}^m x_{ij}^k \cdot R_{j,k} \leq \text{Load}_{i,k}, \quad \forall i = 1, 2, \dots, n, \quad \forall k = 1, 2. \quad (8)$$

$$c_2 = \begin{cases} 0, & \sum_{j=1}^m x_{ij}^k \cdot R_{j,k} \leq \text{Load}_{i,k}; \\ 1, & \text{otherwise.} \end{cases} \quad (9)$$

其中: $R_{j,k}$ 表示幸存者 T_j 所需要的 k 类援助的数量, $k \in \mathbf{K}$; $\text{Load}_{i,k}$ 表示无人机 U_i 所携带的 k 类物资的数量;式(9)表示不满足最大负载约束时所产生的惩罚.

1.3.4 最晚救助时间约束

幸存者的健康状况随时间流逝而逐渐恶化.为保证幸存者的健康和救援的有效,无人机必须在一定时间内完成救援任务,有

$$t_j \leq \text{td}_j, \quad \forall j = 1, 2, \dots, m. \quad (10)$$

$$c_3 = \begin{cases} 0, & t_j \leq \text{td}_j; \\ 1, & \text{otherwise.} \end{cases} \quad (11)$$

其中: td_j 表示幸存者 T_j 的最晚救助时间,式(11)表示不满足最晚救助时间约束时所产生的惩罚.

2 基于AGLPSO的多无人机协同任务分配

本节将提出AGLPSO算法以求解问题的优化模型,详细描述粒子的编码和解码策略,以及两层级联结构中的遗传学习策略、精英学习策略、自适应进化策略.

2.1 面向协同救援任务的粒子编码和解码方法

粒子的位置对应于候选的任务分配方案,对粒子进行灵活的编码可以有效降低问题的复杂性.一个候选的任务分配方案应包含两方面内容:一是执行幸存者救援任务的对应无人机序号;二是无人机执行救援任务的顺序.因此,采用实向量编码的方式对粒子进行编码.根据实向量的特点,可以将一个实数分为整数部分和小数部分:整数部分表示完成对应救援任务的无人机序号;小数部分表示无人机执行该救援任务的先后顺序,数值越小,执行越早.

一个幸存者既需要食物援助,又需要药物援助,但运送这两种救援物资的无人机并不一定相同.这使得在编码过程中应采用两个独立的实数分别表示两种援助任务,以实现不同无人机的任务分配.如果同一幸存者的两类救援任务由同一架无人机完成,则在解码时使对应的两个实数的小数部分等于两者中的最小值,表示两类救援任务同时完成,以提高种群的搜索效率.

以3架无人机救援4个幸存者为例,粒子的编码与解码过程如图1所示.从图1中可以看到, $x_{i,4}$ 和 $x_{i,8}$ 分别对应于幸存者 T_4 的两种援助任务,两者均由无人机 U_1 完成.在解码过程中,如图1中虚线框所示,使 $x_{i,8} = x_{i,4} = 0.5$;然后再根据小数部分的值决定无人机救援顺序,即无人机 U_1 先执行幸存者 T_4 的两种援助任务,再执行幸存者 T_2 的药物援助任务.

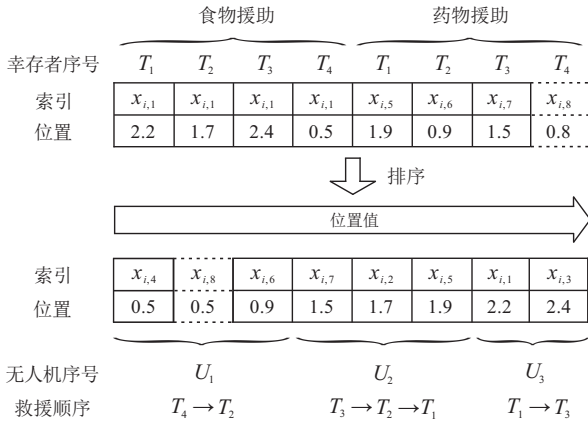


图1 粒子的编码和解码过程

2.2 基于遗传学习的精英粒子生成策略

AGLPSO采用遗传学习策略生成高质量精英种群,用以代替历史最优位置更新粒子位置.其具体包括交叉、变异、选择3种操作,详细描述如下.

首先,基于环形拓扑结构比较当前粒子 i 与随机粒子 k 的历史最优适应度值,以确定所对应的交叉个体中某一维度的值,进而实现交叉操作,即

$$o_{i,d} = \begin{cases} \varphi \cdot \text{pbest}_{n_{i1},d} + (1 - \varphi) \cdot \text{pbest}_{n_{i2},d}, \\ F(\text{pbest}_i) < F(\text{pbest}_k); \\ \text{pbest}_{k,d}, \text{ otherwise.} \end{cases} \quad (12)$$

其中: $\boldsymbol{o}_i = (o_{i,1}, o_{i,2}, \dots, o_{i,D})$ 表示第 i 个交叉个体; $\text{pbest}_i = (\text{pbest}_{i,1}, \text{pbest}_{i,2}, \dots, \text{pbest}_{i,D})$ 表示第 i 个粒子的历史最优位置; D 为搜索空间维度; n_{i1} 和 n_{i2} 表示与第 i 个粒子相邻的两个粒子的索引; φ 为(0,1)之间的随机数; $F(\cdot)$ 表示任务分配问题所对应的适应度函数.

然后,交叉个体每一维度以一个很小的概率 p_{m1} 判断是否变异,若是,则该维度所对应的值重置为搜索空间中的一个随机值,进而实现变异操作,即

$$o_{i,d} = \begin{cases} \text{rand}(\text{lb}_d, \text{ub}_d), \text{ rand}(0, 1) < p_{m1}; \\ o_{i,d}, \text{ otherwise.} \end{cases} \quad (13)$$

其中: lb_d 和 ub_d 分别表示搜索空间中第 d 维的下限和上限, $\text{rand}(0,1)$ 表示(0,1)之间的随机数.

最后,根据贪婪方法将变异生成的候选粒子与上一迭代中对应的精英粒子进行比较,选择更优的个体作为当前迭代的精英粒子,实现选择操作,即

$$\boldsymbol{e}_i = \begin{cases} \boldsymbol{o}_i, F(\boldsymbol{o}_i) < F(\boldsymbol{e}_i); \\ \boldsymbol{e}_i, \text{ otherwise.} \end{cases} \quad (14)$$

其中 $\boldsymbol{e}_i = (e_{i,1}, e_{i,2}, \dots, e_{i,D})$ 表示第 i 个精英粒子.

2.3 基于精英学习的停滞粒子更新策略

在迭代进化过程中,如果连续 sg 次迭代生成的精英粒子适应度值均无变化,则认为该粒子的进化已经停滞.此时,对于精英粒子的每一维,通过锦标赛选择机制,选择适应度值较优的(前20%)两个 pbest 中更优的粒子进行修改,并且有很小的概率 p_{m2} 发生变异.精英学习策略的算法伪代码如表1所示.

表1 精英学习策略

算法1 精英学习策略

- 1) for 每个精英粒子 i
- 2) if 搜索停滞 sg 代
- 3) for 粒子每一维 d
- 4) 随机选择适应度值较优的(前20%)两个 pbest_{r1} 和 pbest_{r2}
- 5) if $f(\text{pbest}_{r1}) < f(\text{pbest}_{r2})$
- 6) $e_{i,d} = \text{pbest}_{r1,d}$
- 7) else
- 8) $e_{i,d} = \text{pbest}_{r2,d}$
- 9) end if
- 10) if $\text{rand}(0, 1) < p_{m2}$
- 11) $e_{i,d} = \text{rand}(\text{lb}_d, \text{ub}_d)$
- 12) end if
- 13) end for
- 14) end if
- 15) end for

此时,精英粒子的每一维可以从不同的较优粒子处进行学习,并有一定概率发生变异,进一步增强了种群的多样性,协助粒子跳出局部最优区域,向潜在的更优区域进行搜索.

2.4 考虑种群进化速度及聚集程度的粒子自适应更新方式

通过精英种群指导粒子速度和位置更新,公式如下:

$$\begin{cases} v_{i,d} = \omega v_{i,d} + c_1 \text{rand}(0, 1)(e_{i,d} - x_{i,d}) + \\ c_2 \text{rand}(0, 1)(\text{gbest}_d - x_{i,d}), \\ x_{i,d} = x_{i,d} + v_{i,d}. \end{cases} \quad (15)$$

其中: $\boldsymbol{x}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$ 和 $\boldsymbol{v}_i = (v_{i,1}, v_{i,2}, \dots, v_{i,D})$ 分别表示第 i 个粒子的位置和速度, $i = 1, 2, \dots, N$, N 为粒子总数; $\text{gbest} = (\text{gbest}_1, \text{gbest}_2, \dots, \text{gbest}_D)$ 表示粒子群搜索到的全局最优位置; ω 为惯性权重; c_1 和 c_2 为学习因子.

惯性权重 ω 的取值对算法性能有着重要的影响.当 ω 较大时,算法具有较强的全局搜索能力;当 ω 较小时,算法则更倾向于进行局部搜索.许多文献中采用线性变化的方式更新 ω 的值,但是,其在面对问题中具有复杂、非线性特性时不够灵活,性能不佳.因

此,本文采用一种自适应更新策略来改变 ω 的值,根据粒子群的进化速度和粒子的聚集程度灵活控制算法的收敛速度。

粒子群的进化速度取决于全局最优值的变化。本文描述的任务分配问题是最小化目标函数的过程,所以粒子群的进化速度因子 h 定义如下:

$$h = \frac{F(\text{gbest}(G))}{F(\text{gbest}(G-1))}, \quad (16)$$

其中 $\text{gbest}(G)$ 表示第 G 次迭代的全局最优位置。由任务分配问题知 $F(\text{gbest}(G-1)) \geq F(\text{gbest}(G)) > 0$,可得 $0 < h \leq 1$,且 h 越小,粒子群的进化速度越快。显然,当粒子群进化速度较快时,算法应保持大范围的全局寻优;当进化速度较慢时,算法应进行小范围的局部搜索,以更快寻找到最优解。

粒子的聚集程度取决于种群中粒子适应度值的接近程度,粒子的聚集度因子 s 定义如下:

$$s = \frac{F(\text{gbest}(G))}{F_{\text{mean}}}, \quad (17)$$

$$F_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N F(x_i). \quad (18)$$

其中: F_{mean} 表示粒子群的平均适应度值, N 为种群中粒子总数。可知 $0 < s \leq 1$,且 s 越小,粒子越分散,算法越不容易陷入局部最优;当粒子聚集时,算法应增大搜索范围,以提高全局寻优能力。

综上所述,惯性权重 ω 应随着粒子群进化速度的降低而减小,随着粒子聚集度的提高而增大,因此,惯性权重 ω 更新如下:

$$\omega = \omega_0 - h\omega_h + s\omega_s, \quad (19)$$

$$\omega_0 = \omega_i - \frac{G}{G_{\text{max}}}(\omega_i - \omega_f). \quad (20)$$

其中: ω_0 为线性变化的基准值; ω_h 、 ω_s 为比例因子; ω_i 、 ω_f 分别为惯性权重基准值的初始值和终值; G 为当前迭代次数; G_{max} 为最大迭代次数。基准值 ω_0 保证 ω 的总体变化趋势是逐渐减小的,使得算法可以在迭代初期进行全局搜索,寻找更可能的最优解区域;在迭代后期,进行局部搜索,更快收敛到最优解。在此基础上, ω 根据粒子群的进化速度和粒子的聚集程度上下浮动,以灵活控制算法收敛。

学习因子 c_1 、 c_2 采用线性变化的方式进行更新,即

$$c_1 = c_{1\text{max}} - \frac{G}{G_{\text{max}}}(c_{1\text{max}} - c_{1\text{min}}), \quad (21)$$

$$c_2 = c_{2\text{min}} + \frac{G}{G_{\text{max}}}(c_{2\text{max}} - c_{2\text{min}}). \quad (22)$$

其中: $c_{1\text{max}}$ 、 $c_{1\text{min}}$ 和 $c_{2\text{max}}$ 、 $c_{2\text{min}}$ 分别为学习因子 c_1 和 c_2 的最大值、最小值。

2.5 AGLPSO求解协同任务分配问题的步骤

采用AGLPSO算法求解多无人机协同任务分配问题过程如下。

step 1: 根据救援场景输入无人机和幸存者的初始信息。

step 2: 设置算法最大迭代次数 G_{max} ;粒子个数 N ;惯性权重 ω 基准值的初始值和终值 ω_i 、 ω_f ;学习因子 c_1 、 c_2 的上下限 $c_{1\text{max}}$ 、 $c_{1\text{min}}$ 、 $c_{2\text{max}}$ 、 $c_{2\text{min}}$;变异率 p_{m1} 、 p_{m2} ;最大停滞代数 sg ;比例因子 ω_h 、 ω_s ;初始化迭代次数 $G = 0$;初始化粒子种群。

step 3: 根据式(1)~(11)计算粒子个体适应度,更新粒子历史最优位置和全局最优位置。

step 4: 采用遗传学习策略生成精英粒子,更新全局最优位置。

step 5: 采用精英学习策略更新停滞精英粒子。

step 6: 根据式(16)~(22)计算惯性权重和学习因子。

step 7: 根据式(15)更新粒子速度和位置。

step 8: 根据式(1)~(11)计算粒子个体适应度,更新粒子历史最优位置和全局最优位置。

step 9: 更新迭代次数 $G = G + 1$,判断是否满足 $G \leq G_{\text{max}}$ 。若是则转到step 4;否则算法结束。step 8中得到的全局最优位置即为最优解。

step 10: 对最优解解码,得到算法规划出的最优救援方案。

3 实验结果对比和分析

为了验证改进后的AGLPSO算法求解多无人机协同任务分配问题的有效性,本文采用Matlab2018a仿真软件进行多组仿真实验。假设救援场景是从两个固定机场出发的多架不同无人机救援分散在 $100 \text{ km} \times 100 \text{ km}$ 空间范围内的幸存者。所有无人机的速度恒定为 1 km/min 。设置算法AGLPSO中参数: $N = 20$, $\omega_i = 0.9$, $\omega_f = 0.4$, $\omega_1 = \omega_2 = 1$, $\omega_3 = 500$, $c_{1\text{max}} = c_{2\text{max}} = 2.5$, $c_{1\text{min}} = c_{2\text{min}} = 0.5$, $p_{m1} = p_{m2} = 0.01$, $\text{sg} = 7$, $\omega_h = 0.4$, $\omega_s = 0.1$ 。比较算法PSO^[19]、HFPSO^[20]、CLPSO^[21]、EPSO^[22]、GGLPSOD^[17]的参数设置均与所对应文献中相同。

3.1 不同场景下的仿真实验结果

选取两个救援任务场景验证AGLPSO算法的有效性。在两个场景中,由3架无人机救援10个幸存者。因为不同算法每次迭代进化过程中,函数的评价次数不同,所以采用最大函数评价次数 FE_{max} 作为算法迭代的终止条件,设 $\text{FE}_{\text{max}} = 1000$ 。为降低算法中随机性的影响,每种算法独立运行20次。

表2显示了在场景1中,6种算法规划的救援方案的统计结果.其中列出了所对应的适应度值的最优值、平均值、中位值、最差值和标准差,规划一次救援方案的平均时间,以及规划的成功率(即得到满足所有约束的救援方案的次数占实验总次数的百分比).表3显示了在场景2中得到的统计结果.图2是表2中统计数据所对应的箱线图.图3是场景1中6种算法平均适应度值的收敛曲线.图4是表3中统计数据所对应的箱线图.图5是场景2中6种算法平均适应度值的收敛曲线.图6和图7分别是场景1和场景2中6种算法规划出的最优救援方案.

表2 场景1中6种算法的统计数据

方法	最优值	平均值	中位值	最差值	标准差	平均时间/s	成功率/%
PSO	551.41	686.58	692.73	814.81	78.45	0.93	95
HFPSO	571.47	728.34	743.61	889.00	85.87	0.96	80
CLPSO	562.00	666.85	637.45	877.96	89.09	0.98	85
EPSO	535.93	611.77	604.28	727.44	50.05	1.11	100
GGL-PSOD	486.28	615.49	601.52	761.42	75.92	0.94	100
AGLPSO	479.17	605.29	592.35	717.42	65.88	0.93	100

表3 场景2中6种算法的统计数据

方法	最优值	平均值	中位值	最差值	标准差	平均时间/s	成功率/%
PSO	612.35	748.47	727.37	900.50	88.59	1.23	75
HFPSO	571.60	718.30	707.71	859.77	104.77	1.36	45
CLPSO	500.15	654.60	663.88	866.09	92.89	1.32	95
EPSO	543.36	640.98	640.08	743.36	68.23	1.40	100
GGL-PSOD	470.68	611.69	611.29	752.13	79.59	1.18	100
AGLPSO	470.68	607.38	608.46	724.02	81.86	1.19	100




图2 场景1中统计数据所对应的箱线图




图3 场景1中平均适应度收敛曲线

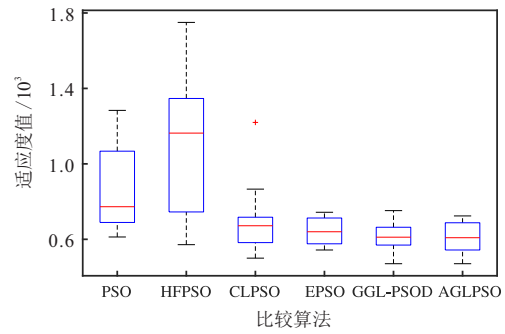


图4 场景2中统计数据所对应的箱线图




图5 场景2中平均适应度收敛曲线

从上述两个实验结果可以看到,在平均运行时间几乎相同的情况下,6种算法中EPSO、GGL-PSOD、AGLPSO规划的成功率能达到100%.相比于其他比较算法,尽管AGLPSO算法得到的标准差稍差,但其表现出的整体性能最好,得到的最优值、平均值、中位值、最差值都是最优的.仿真结果表明,改进的AGLPSO算法能有效解决不同场景下的多无人机协同任务分配问题,找到最优的救援方案.

3.2 不同幸存者数量下的算法性能对比

幸存者的数量决定粒子的维度,随着其不断增加,粒子的维度会越来越大,寻优的难度会越来越高.本节进一步研究AGLPSO算法在不同幸存者数量下处理多无人机协同任务分配问题的性能.实验选取10架无人机救援30、40、50、60、70、80、90、100个幸存者的场景,进行了8组仿真实验.设置最大函数评价次数 $FE_{max} = 20000$,每种算法独立运行20次.

表4显示了不同幸存者数量下6种算法的统计数据.从中可以看出,AGLPSO在8组实验场景中规划得到的最优值和平均值都优于其他5种比较算法.还可以看出,GGL-PSOD和AGLPSO都能收敛到较优的解,但GGL-PSOD在迭代前期收敛缓慢,而AGLPSO收敛速度更快,说明所提出的自适应策略能有效根据种群进化情况选择合适的惯性权重,提高算法寻优能力.仿真结果表明,随着救援任务规模的增大,AGLPSO算法依旧能表现出良好的性能,可以得到较优的救援方案.

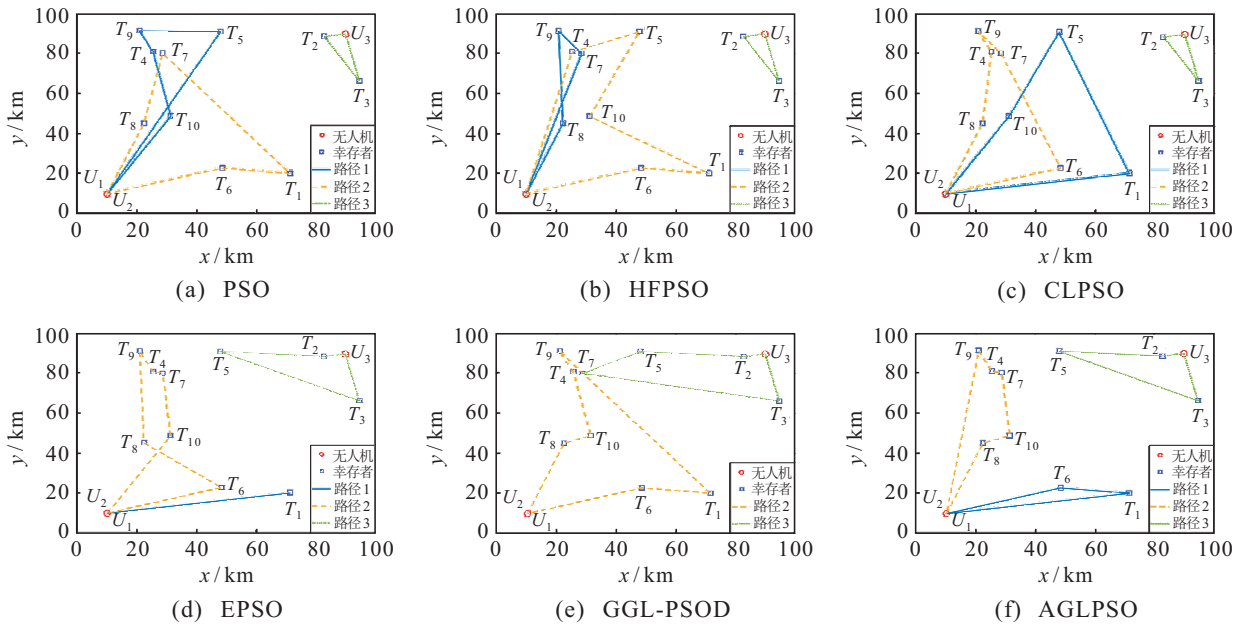


图6 场景1中最优救援方案

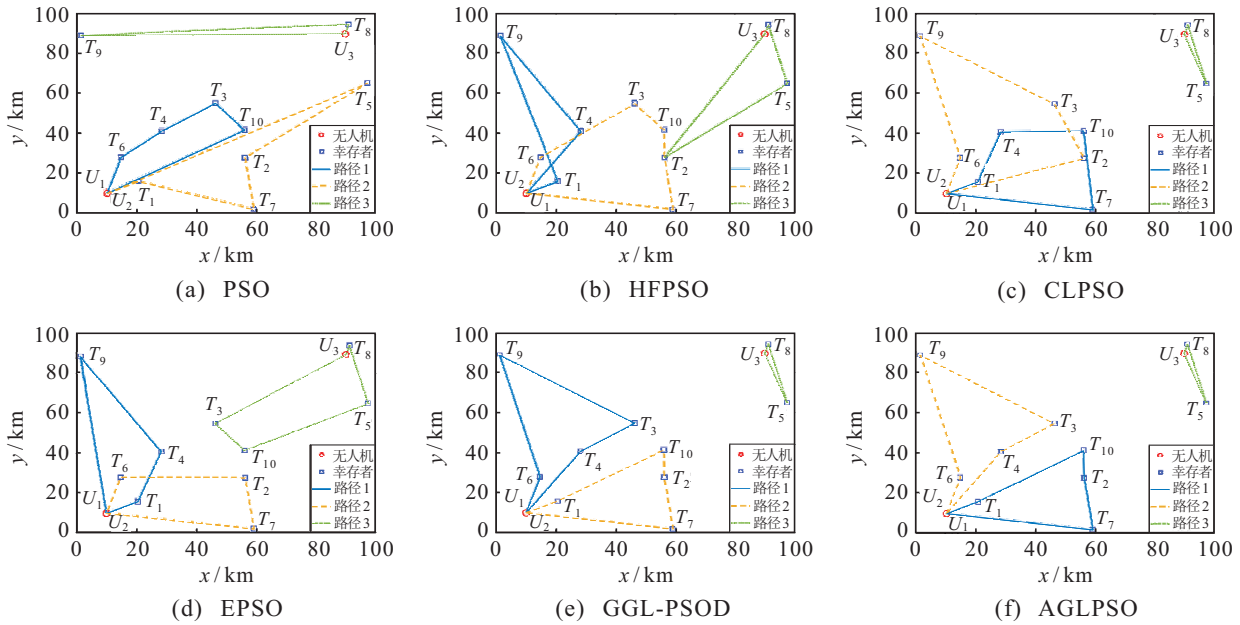


图7 场景2中最优救援方案

3.3 不同无人机数量下的算法性能对比

无人机的数量决定粒子每一维度的上下限,随着其不断增大,粒子的搜索空间会变得越来越大,对算法的局部搜索能力要求越来越高.所以本节进一步研究AGLPSO算法在不同无人机数量下处理多无人机协同任务分配问题的性能.实验选取3、4、5、6、8、10、20、30、50架无人机救援50个幸存者的场景,进行了9组仿真实验.设置最大函数评价次数 $FE_{max} = 20000$,每种算法独立运行20次.

表5显示了不同无人机规模下6种算法的统计数据.从中可以看出,AGLPSO在所有实验场景中规划得到的最优值和平均值都优于其他5种比较算

法.仿真结果表明,随着无人机数量的增加,AGLPSO算法在6种算法中依旧表现出了最好的性能,可以得到最优的救援方案.

4 结论

本文研究救援场景下的多无人机协同任务分配问题.为更符合实际救援任务情况,在考虑幸存者需要多种救援物资的任务需求基础上,建立了具有不同援助类型的幸存者救援模型,进而提出了一种自适应遗传学习粒子群算法对该模型进行求解.算法首先设计了一种实向量编码和解码机制,以表示无人机与幸存者之间的复杂救援关系,从而降低问题复杂性.然后,为了提高算法寻优能力,采用一种两层级联

表4 不同幸存者数量下6种算法的统计数据

算法	指标	$m = 30$	$m = 40$	$m = 50$	$m = 60$	$m = 70$	$m = 80$	$m = 90$	$m = 100$
PSO	最优值	1916.14	2459.31	4560.14	4560.14	5756.72	6441.29	7031.55	8470.78
	平均值	2124.30	3103.14	4054.64	5078.48	6062.53	6778.63	7715.85	8778.87
HFPSO	最优值	1265.76	1496.12	2432.05	2432.05	3082.51	3672.08	3981.68	4646.08
	平均值	1508.27	1934.25	2413.09	3012.64	3649.60	4082.03	4539.52	5252.86
CLPSO	最优值	1175.91	1677.35	3545.50	3545.50	3899.03	5416.45	6151.82	6973.94
	平均值	1317.23	1988.98	2895.77	3876.01	4746.53	5666.35	6598.28	7805.62
EPSO	最优值	1174.07	1416.70	1985.66	1985.66	2311.06	2496.05	3137.57	3114.25
	平均值	1253.23	1608.17	1879.07	2220.34	2603.84	2953.57	3487.88	3864.20
GGL-PSOD	最优值	911.49	1174.91	1547.12	1547.12	1820.73	1994.98	2213.68	2553.02
	平均值	1067.81	1328.39	1614.34	1860.69	2022.22	2305.99	2513.59	2791.31
AGLPSO	最优值	884.11	1027.91	1476.01	1476.01	1730.93	1865.51	2123.14	2262.33
	平均值	1031.32	1227.78	1517.27	1713.13	1930.81	2141.61	2383.19	2611.32

表5 不同无人机数量下6种算法的统计数据

算法	指标	$n = 3$	$n = 4$	$n = 5$	$n = 6$	$n = 8$	$n = 10$	$n = 20$	$n = 30$	$n = 50$
PSO	最优值	2666.0	2826.8	3054.4	3269.0	3329.8	3763.7	4168.9	4423.0	5067.0
	平均值	3331.0	3245.6	3528.1	3736.5	3766.6	4066.0	4584.6	5049.4	5546.0
HFPSO	最优值	1703.4	1910.3	1931.6	2152.8	1997.0	2102.0	2605.6	2453.9	2797.5
	平均值	2145.2	2211.7	2224.0	2418.9	2362.7	2461.7	2964.0	3080.0	3522.8
CLPSO	最优值	2267.7	2106.0	2221.2	2366.2	2274.8	2441.0	2361.5	2259.8	2584.9
	平均值	2567.8	2395.5	2590.5	2795.3	2695.4	2922.5	2906.8	2920.5	3238.4
EPSO	最优值	1314.5	1372.0	1466.4	1473.0	1536.5	1652.1	1770.1	1921.7	2151.8
	平均值	1428.5	1464.4	1598.2	1691.5	1774.7	1919.7	2100.4	2429.6	2797.7
GGL-PSOD	最优值	1193.9	1202.3	1294.9	1405.1	1296.8	1347.2	1449.2	1582.4	1525.0
	平均值	1305.5	1367.0	1457.7	1535.0	1533.5	1594.0	1706.1	1785.6	1841.6
AGLPSO	最优值	1128.2	1191.4	1264.9	1226.6	1264.4	1238.3	1336.5	1382.7	1429.6
	平均值	1282.5	1324.2	1432.7	1433.4	1439.3	1505.8	1499.8	1611.3	1649.7

结构,通过第1层中遗传学习策略和精英学习策略生成高质量的精英粒子,以指导第2层中粒子种群的搜索方向,同时提出了自适应进化策略以动态调整惯性权重的值,实现算法收敛速度的灵活控制.多组仿真实验表明,所提出的AGLPSO算法能有效解决多无人机协同任务分配问题,且在大规模救援场景中具有良好的搜索性能,可以找到较优的救援方案.相比于其他优化算法,AGLPSO算法寻优能力更强,且可以根据不同搜索情况灵活控制收敛速度.

对于下一步工作,将着重研究动态场景下的任务分配问题,考虑任务实际执行过程中的突发情况,为救援方案的动态调整留出空间,保证方案的合理、鲁棒和可拓展性.

参考文献(References)

- [1] Zhou Y M, Zhao H R, Chen J F, et al. A novel mission planning method for UAVs' course of action[J]. Computer Communications, 2020, 152: 345-356.
- [2] 赵明, 苏小红, 马培军, 等. 复杂多约束UAVs协同目标分配的一种统一建模方法[J]. 自动化学报, 2012, 38(12): 2038-2048.
(Zhao M, Su X H, Ma P J, et al. A unified modeling method of UAVs cooperative target assignment by complex multi-constraint conditions[J]. Acta Automatica Sinica, 2012, 38(12): 2038-2048.)
- [3] Zhen Z Y. An intelligent cooperative mission planning scheme of UAV swarm in uncertain dynamic environment[J]. Aerospace Science and Technology, 2020, 100: 105826.
- [4] D'Emidio M. Collision-free allocation of temporally

- constrained tasks in multi-robot systems[J]. *Robotics and Autonomous Systems*, 2019, 119: 151-172.
- [5] 陈志旺, 夏顺, 李建雄, 等. 考虑分配次序的无人机协同目标分配建模与遗传算法求解[J]. *控制理论与应用*, 2019, 36(7): 1072-1082.
(Chen Z W, Xia S, Li J X, et al. Modeling of unmanned aerial vehicles cooperative target assignment with allocation order and its solving of genetic algorithm[J]. *Control Theory & Applications*, 2019, 36(7): 1072-1082.)
- [6] 黄刚, 李军华. 基于AC-DSDE进化算法多UAVs协同目标分配[J]. *自动化学报*, 2021, 47(1): 173-184.
(Huang G, Li J H. Multi-UAV cooperative target allocation based on AC-DSDE evolutionary algorithm[J]. *Acta Automatica Sinica*, 2021, 47(1): 173-184.)
- [7] Wang Z, Liu L, Long T, et al. Multi-UAV reconnaissance task allocation for heterogeneous targets using an opposition-based genetic algorithm with double-chromosome encoding[J]. *Chinese Journal of Aeronautics*, 2018, 31(2): 339-350.
- [8] Zhao W Q, Meng Q G, Chung P W H. A heuristic distributed task allocation method for multivehicle multitask problems and its application to search and rescue scenario[J]. *IEEE Transactions on Cybernetics*, 2016, 46(4): 902-915.
- [9] 张进, 郭浩, 陈统. 基于可适应匈牙利算法的武器-目标分配问题[J]. *兵工学报*, 2021, 42(6): 1339-1344.
(Zhang J, Guo H, Chen T. Weapon-target assignment based on adaptable Hungarian algorithm[J]. *Acta Armamentarii*, 2021, 42(6): 1339-1344.)
- [10] Chen X Y. A distributed method for dynamic multi-robot task allocation problems with critical time constraints[J]. *Robotics and Autonomous Systems*, 2019, 118: 31-46.
- [11] Zhao X Y. Fast task allocation for heterogeneous unmanned aerial vehicles through reinforcement learning[J]. *Aerospace Science and Technology*, 2019, 92: 588-594.
- [12] Wu H, Shang H L. Potential game for dynamic task allocation in multi-agent system[J]. *ISA Transactions*, 2020, 102: 208-220.
- [13] 杜永浩, 邢立宁, 蔡昭权. 无人飞行器集群智能调度技术综述[J]. *自动化学报*, 2020, 46(2): 222-241.
(Du Y H, Xing L N, Cai Z Q. Survey on intelligent scheduling technologies for unmanned flying craft clusters[J]. *Acta Automatica Sinica*, 2020, 46(2): 222-241.)
- [14] 李炜, 张伟. 基于粒子群算法的多无人机任务分配方法[J]. *控制与决策*, 2010, 25(9): 1359-1363.
(Li W, Zhang W. Method of tasks allocation of multi-UAVs based on particles swarm optimization[J]. *Control and Decision*, 2010, 25(9): 1359-1363.)
- [15] Ho S Y, Lin H S, Liauh W H, et al. OPSO: Orthogonal particle swarm optimization and its application to task assignment problems[J]. *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, 2008, 38(2): 288-298.
- [16] Gong Y J, Li J J, Zhou Y C, et al. Genetic learning particle swarm optimization[J]. *IEEE Transactions on Cybernetics*, 2016, 46(10): 2277-2290.
- [17] Lin A P, Sun W, Yu H, et al. Global genetic learning particle swarm optimization with diversity enhancement by ring topology[J]. *Swarm and Evolutionary Computation*, 2019, 44: 571-583.
- [18] Geng N, Meng Q G, Gong D W, et al. How good are distributed allocation algorithms for solving urban search and rescue problems? A comparative study with centralized algorithms[J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(1): 478-485.
- [19] Clerc M, Kennedy J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(1): 58-73.
- [20] Aydilek İ B. A hybrid firefly and particle swarm optimization algorithm for computationally expensive numerical problems[J]. *Applied Soft Computing*, 2018, 66: 232-249.
- [21] Liang J J, Qin A K, Suganthan P N, et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10(3): 281-295.
- [22] Lynn N. Ensemble particle swarm optimizer[J]. *Applied Soft Computing*, 2017, 55: 533-548.

作者简介

张祥银(1986—), 男, 副教授, 博士生导师, 从事无人系统自主控制与决策优化、群智能优化、机器人控制等研究, E-mail: xy_zhang@bjut.edu.cn;

夏爽(1997—), 男, 硕士生, 从事群体智能优化算法的研究, E-mail: xias@emails.bjut.edu.cn;

张天(1997—), 男, 硕士生, 从事多机器人编队控制的研究, E-mail: tian-zhang@emails.bjut.edu.cn.