基于鸽群智能行为的大规模无人机集群聚类优化算法

霍梦真, 魏晨*, 于月平, 赵建霞

北京航空航天大学自动化科学与电气工程学院, 仿生自主飞行系统研究组, 北京 100083

* E-mail: weichen@buaa.edu.cn

收稿日期: 2019-09-05; 接受日期: 2019-11-14; 网络版发表日期: 2020-02-20

科技创新2030-“新一代人工智能”重大项目(编号: 2018AAA0102303, 2018AAA0102403)和国家自然科学基金项目(编号: 91948204, 91648205, 61425008, U1913602, U19B2033)资助

摘要 未来空中战场, 大规模无人机集群系统将成为主导力量. 而对大规模无人机集群系统进行分组聚类是完成作战任务规划的必要步骤. 在实际战场中无人机受到有限通信约束, 无法得到全面而有效的全局作战信息. 因此本文提出一种基于鸽群智能行为的大规模无人机集群聚类优化算法. 根据聚类模型设计鸽群优化算法, 研究分析导航能力优异的鸽群智能行为, 将鸽群飞行过程中的层级网络机制映射到鸽群优化算法中, 解决有限交互环境下的信息不完整问题. 一方面, 依据鸽群在飞行过程中来自临近个体的引导更为有效直接, 因而在有限交互环境下, 基本鸽群优化算法中的全局最优信息由交互范围内的最优个体信息替代; 另一方面, 鸽群的中心位置更新包括三部分: 增量惯性部分、模仿部分、环境影响部分. 为验证改进后鸽群优化算法在有限交互范围下的有效性, 本文采用三种算法针对三个数据集进行聚类分组, 仿真结果表明改进后的鸽群优化算法在最优解与平均最优解上均有改善, 为实际作战环境下的无人机集群系统聚类分组提供了有效的解决方法.

关键词 无人机集群, 聚类分组, 鸽群智能行为, 鸽群优化算法

1 引言

无人机以其生存能力强、可回收、可重复使用等优势在电网巡检、森林防护、搜索与救援、航拍等民用领域以及目标侦察、跟踪、打击等军事领域都有着广泛应用^[1], 并且已在过去的多次局部战争中发挥了重要作用, 因而受到广泛关注. 作为未来空中战场的主要力量, 大规模无人机集群系统在执行对地、对海、对空协同作战任务时, 考虑无人机性能以及任务

类型约束下, 如何合理分组无人机去执行相关任务使得系统总收益最大成为无人机集群系统亟待解决的问题. 尽管已经做了大量的研究, 无人机聚类分组的计算复杂度仍然是多无人机协同任务中的一个关键问题. 在寻找最优解和降低计算成本之间存在权衡. 通常, 一个平衡介于两者之间, 在可接受的计算时间内产生一个相对较好的解. 聚类分析是降低复杂优化问题计算成本的一种可行方法, 能够在可接受的计算时间内对大规模无人机集群进行有效的分组.

引用格式: 霍梦真, 魏晨, 于月平, 等. 基于鸽群智能行为的大规模无人机集群聚类优化算法. 中国科学: 技术科学, 2020, 50: 475–482

Huo M Z, Wei C, Yu Y P, et al. Clustering optimization algorithm for large-scale unmanned aerial vehicle based on intelligent behavior of pigeons (in Chinese). Sci Sin Tech, 2020, 50: 475–482, doi: 10.1360/SST-2019-0317

聚类分析是数据挖掘技术中的一个重要研究方向, 是一种用于数据划分或分组处理的重要手段. 在大规模无人机分组作战应用中, 聚类分析可作为数据挖掘系统中的一个模块, 发现数据库中数据分布的深层信息. 因此, 研究如何提高聚类算法的性能对于大规模无人机分组作战具有重要的意义.

对聚类算法的研究始于20世纪60年代初, 经典聚类方法包括分层算法、划分方法(如K均值算法、模糊C均值算法)、图论聚类法、神经网络法以及基于统计的方法等. 近年来随着对数据挖掘领域的深入研究, 涌现了大量新的聚类算法, 包括基于群体智能的聚类算法等.

群体智能^[2-4]利用群体优势, 在没有集中控制、不提供全局模型的前提下, 为寻找复杂问题解决方案提供了新的思路, 是“简单智能体通过合作表现出智能行为的特性”. 作为群体智能的典型实现模式, 模拟生物智能的优化算法正在受到学术界的广泛关注, 取得诸多研究成果^[5-7].

近年来, 鸽群因其具有惊人的导航能力且易于饲养而备受关注. 在导航能力方面, Guilford等人^[8]发现鸽子会在旅程不同阶段使用不同导航工具, 前期依赖磁场, 后期依赖地标^[9]. Whiten^[10]发现太阳高度也会影响鸽子导航. Duan和Qiao^[11]受此启发, 提出了一种新型仿生智能计算方法——鸽群优化算法, 该算法在许多优化问题中具有较快的求解速度与较好的拓展性^[12-14]. 在群体机制方面, Nagy等人^[15,16]通过微型全球定位系统(global positioning system, GPS)记录鸽群飞行数据, 分析鸽子个体跟随关系, 确定鸽群内部层级网络机制.

基于有限通信约束条件, 本文提出一种基于鸽群智能行为的大规模无人机集群聚类优化算法. 根据聚类模型设计鸽群优化算法, 研究分析导航能力优异的鸽群智能行为, 将鸽群飞行过程中的层级网络机制映射到鸽群优化算法中, 解决有限交互环境下的信息不完整问题. 一方面, 依据鸽群在飞行过程中来自临近个体的引导更为有效直接, 因而在有限交互环境下, 基本鸽群优化算法中的全局最优信息由交互范围内的最优个体信息替代; 另一方面, 改进后的鸽群的中心位置更新包括三部分: 增量惯性部分、模仿部分、环境影响部分. 旨在为实际作战环境下的无人机集群系统聚类分组提供有效的解决方法.

2 鸽群智能行为机制

2.1 鸽群导航行为机制

据观察实验发现, 鸽群归巢行为主要受以下三种因素影响: 太阳、地球磁场与地标, 鸽子将在归巢的不同阶段使用不同的导航工具. 英国学者Guilford等人^[8]借助数学模型预测了鸽子在归巢过程中的导航工具切换机制. 国内外学者通过研究鸽群导航行为发现: 在鸽群飞行的初始阶段, 鸽群较大程度上依赖太阳与地球磁场进行导航; 而当接近目的地时, 鸽子对目的地周围的建筑较为熟悉, 因而更多依靠路途中的地标进行导航, 此过程中不断对当前的路线进行评价与修正.

基于鸽群在归巢过程中的特殊导航行为, Duan和Qiao^[11]于2014年提出了一种仿生群体智能优化算法——鸽群优化算法. 在该算法中, 通过模仿鸽群寻找目的地的导航机制, 设计目标向量寻求全局最优解的迭代过程, 提出了2种算子模型.

(1) 地图和指南针算子

地图和指南针算子模拟鸽子的地球磁场与太阳高度感知能力. 鸽子大脑中的特殊部位具有磁性物体, 能够感知地球磁场, 然后在头脑中形成地图; 同时它们能够感知太阳高度, 并将其作为指南针来调整飞行方向. 当鸽群逐渐接近目的地时, 他们对地球磁场与太阳的依赖性也逐渐减小.

(2) 地标算子

地标算子模拟飞行后半阶段中地标对鸽子的影响. 当鸽群逐渐接近目的地时, 对地标的熟悉程度将更大程度地影响他们对目的地方向的调整. 对地标熟悉的鸽子将成为鸽群的领导者, 而对地标熟悉度差的鸽子将跟随其他鸽子进行飞行, 其中部分鸽子将逐渐远离鸽群, 直至脱离群体.

2.2 鸽群层级网络机制

在鸽群飞行过程中, 总是保持着严格的层级网络机制, 当前行遇到障碍或突发威胁时, 能够根据群体层级关系由上至下进行快速的反应, 越过障碍或躲避威胁. 针对这一现象, 学者Nagy等人^[15,16]对鸽群的层级网络机制进行试验. 实验过程中, 采用背负式定位给鸽子佩戴GPS设备, 记录飞行过程中鸽群的位置与速度信息. 通过对数据进行处理, 分析鸽子之间速度

的关联性, 可判断每个时刻具有相互跟随关系的鸽子个体, 从而确定鸽群的层级网络机制. 实验结果表明鸽群的确存在等级制度, 但并非简单领导者-跟随者模式, 而是复杂层级网络机制. 研究结果发现, 鸽群中存在多层等级结构, 头鸽处于绝对领导地位, 其余跟随鸽下层服从上层, 下层鸽子的行为无法影响上层鸽子的决策. 即: 每一层鸽子不仅受最高层头鸽的影响, 同时还受其上层其他鸽子的影响, 而且在突发情况下, 来自临近上层鸽子的影响更为直接迅速. 基于以上机制, 可建立鸽群层级网络.

鸽群层级网络结构可采用有向图 $D=(V, E)$ 进行描述^[17], 其中, $V=\{v_1, v_2, \dots, v_n\}$ 与 $E=\{e_1, e_2, \dots, e_n\}$ 分别表示有向图的顶点集和边集, n 为鸽群规模, 顶点表示鸽群个体, 边表示鸽群个体之间的上下级关系, 如图1所示. 由图1可以看出, 头鸽不受其他个体的影响, 一级鸽子受头鸽的飞行引导, 二级鸽子受一级鸽子与头鸽的引导, 以此类推; 实线表示临近个体的引导作用更为直接, 虚线表示较远的上级鸽子对下级鸽子的引导.

3 聚类优化算法设计

3.1 聚类模型设计

3.1.1 算法变量设计

设粒子群的聚类个数为 k , 记为 $C=\{C_1, C_2, \dots, C_k\}$, 则算法的变量由 k 个聚类中心组成, 作为聚类优化算法的输入. 若聚类数据的向量维数为 d , 则聚类算法位置

图1 (网络版彩图) 鸽群层级网络机制

Figure 1 (Color online) Hierarchy network mechanism of pigeons.

变量与速度变量的维度都应为 $k \times d$ 维, 由聚类中心位置到聚类算法变量的转换如图2所示.

3.1.2 算法适应度函数设计

针对输入变量 $[x_{11}, \dots, x_{1d}, x_{21}, \dots, x_{2d}, \dots, x_{k1}, \dots, x_{kd}]$ 可求得 k 个聚类中心位置, 每个聚类数据根据最近邻法则确定所属类, 即若 $\|D_i - X_j\| = \min_{0 \leq m \leq k} \|D_i - X_m\|$, 则第 i 个数据属于第 j 类. 获得每个聚类数据的所属类, 则可计算类间离散度 J :

$$J = \sum_{j=1}^k \sum_{X_i \in C_j} \|X_i - D_j\|. \quad (1)$$

J 越小表明聚类效果越好, 因而算法适应度函数可使用离散度函数表示.

3.2 自学习鸽群优化算法设计

基本的鸽群优化算法基于两个算子进行迭代以寻求最优解, 第一阶段依赖地图和指南针算子, 第二阶段依赖地标算子. 基本的鸽群优化算法具有明显的弊端, 比如易陷入局部最优解, 求高维解困难等, 即无人机集群聚类优化问题的求解难点. 而且在大规模无人机集群聚类分组过程中, 无人机的机载计算机无法获取全局信息, 且易出现信息不完整、丢包等情况, 使得无人机难以在单个机载计算机上进行全局最优解计算,

图2 聚类算法变量转换

Figure 2 Variable conversion of clustering algorithm.

因而基本的鸽群优化算法无法适用于大规模无人机集群分组优化问题. 针对上述需求, 本文基于鸽群智能行为提出自学习鸽群优化算法, 将鸽群层级网络机制融入鸽群导航行为机制, 使得鸽群优化算法能够在有限交互范围条件下向优异的邻居个体学习, 而不需要获取全局个体信息, 以较短的时间寻求到接近最优解的位置, 即聚类优化问题的输出.

3.2.1 地图和指南针算子

首先在搜索空间中, 定义鸽群个体的位置 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$ 和速度 $\mathbf{V}_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$, 地图和指南针因数定义为 R . 随着迭代次数的增加, 鸽子不断向交互范围内的最优个体进行学习, 实时更新自己的速度 $\mathbf{V}_i$ 以及位置 $\mathbf{X}_i$:

$$\mathbf{V}_i(t) = \mathbf{V}_i(t-1) \cdot e^{-Rt} + \text{rand} \cdot (\mathbf{X}_{\text{local\_best}} - \mathbf{X}_i(t-1)), \quad (2)$$

$$\mathbf{X}_i(t) = \mathbf{X}_i(t-1) + \mathbf{V}_i(t), \quad (3)$$

其中, t 为当前的迭代次数, $0 \leq t \leq T_{\text{clmax}}$ 且 T_{clmax} 为此循环的最大迭代次数, R 取值为 0.02, rand 为随机数, 在 (0, 1) 之间均匀分布, $\mathbf{X}_{\text{local\_best}}$ 为鸽子交互范围内的最优解.

基于鸽群的层级网络机制, 下层鸽子行为不仅受头鸽影响, 也受其他上层鸽子的影响, 而往往来自于临近上级的影响更为直接迅速, 这使得在突发情况下鸽群能够有效避开危险物并保持原有的队形, 向着目的地方向前进. 在鸽群优化算法中, 目的地即所求的全局最优解, 临近上级即交互范围内的优异个体. 由于约束条件为无法获取全局信息, 因而来自优异邻居个体的指导更为直接迅速, 这使得在有限交互范围约束下鸽子需通过向交互范围内的邻居个体进行学习, 其求解过程如下:

(1) 令 $N_i \subseteq \{1, 2, \dots, n\}$ 表示对鸽子 i 存在领导作用的上级鸽子集合, 根据鸽子的交互约束条件, 可根据约束距离 r 确定鸽子在 t 时刻的交互个体集合 $N_i = \{X_m: \|X_m - X_i\| \leq r\}$;

(2) 对集合 N_i 中的个体进行适应度函数评价并排序, 使得适应度函数值最低的个体即为当前鸽子的最优邻居, 即可求得 $\mathbf{X}_{\text{local\_best}}$, 如图 3 所示.

上述循环直到 $t > T_{\text{clmax}}$ 时停止, 进入第二个循环.

3.2.2 地标中心算子

在鸽群逐渐接近目的地的过程中, 地图和指南针

图 3 (网络版彩图)有限交互范围自学习机制

Figure 3 (Color online) Self-learning mechanism for limited interaction.

的作用逐渐衰弱, 地标算子成为导航的主要影响因子, 同时, 逐渐远离目的地的鸽子对地标熟悉度较差, 将与鸽群脱离而被舍弃, 剩余的鸽子在地标算子的指引下逐渐接近目的地.

基本的鸽群优化算法对于地标中心位置 $\mathbf{X}_{\text{center}}$ 的求解需依靠全局个体的位置信息与适应度函数值, 给通信条件带来较高的要求, 也给机载计算机带来较大的计算压力, 因而本文受文献[18]启发提出自学习机制, 在局部交互的情况下指引鸽群快速找到目的地. 自学习机制主要针对地标中心位置 $\mathbf{X}_{\text{center}}$ 的计算, $\mathbf{X}_{\text{center}}$ 的迭代增量由三部分组成: 增量惯性部分、模仿部分、环境影响部分. 其中, 惯性部分继承上一时刻的中心位置更新, 模仿部分向交互范围内的最优信息学习, 环境影响部分跟随邻居个体的整体趋势进行移动. 其迭代过程如下:

$$\Delta \mathbf{X}_{\text{center}}(t+1) = \varepsilon_1 \cdot \Delta \mathbf{X}_{\text{center}}(t) + \varepsilon_2 \cdot I_i + \varepsilon_3 \cdot C_i, \quad (4)$$

$$\mathbf{X}_{\text{center}}(t+1) = \Delta \mathbf{X}_{\text{center}}(t+1) + \mathbf{X}_{\text{center}}(t), \quad (5)$$

其中, $\varepsilon_1, \varepsilon_2, \varepsilon_3$ 为 (0,1) 之间均匀分布的随机数, I_i 为社会学习元素, C_i 为群体平均影响元素, 求解过程如下:

$$\begin{cases} I_i = X_{\text{local\_best}} - X_i, \\ C_i = \bar{X}_m - X_i, \end{cases} \quad (6)$$

其中, X_i 为第 i 个鸽子的当前位置, $X_{\text{local\_best}}$ 为交互范围内最优解, $\bar{X}_m$ 为交互范围内的个体平均位置

$$(\bar{X}_m = \sum_{m \in N_i} X_m / \text{size}(N_i)).$$

由于鸽群的交互范围受到限制, 因而此时鸽群的导航能力相比之前受到较大的削弱, 使得寻优能力降低; 而自学习机制通过模仿鸽群在飞行过程中的层级网络机制, 建立起约束条件下的寻优机制, 使得鸽群在有限交互范围条件下也能够以较快的速度接近目的地, 即找到无人机集群聚类优化问题的较优输出。

4 算法验证

为了验证自学习鸽群优化算法在聚类分析中的有效性, 本文开展了3组对比试验如表1所示, 采用粒子群优化算法(PSO)、鸽群优化算法(PIO)与自学习鸽群优化算法(SLPIO)进行数据对比, 每个算法进行20次无差别重复试验, 仿真条件均为等大的有限交互范围。

4.1 Iris数据集对比验证

由表1可知, Iris数据集具有4个特征, 分为3类, 则转换到优化算法中, 变量维度为12。对每个算法进行无差别20次仿真取其最优结果, 结果如图4所示, 三类算

表 1 三组聚类数据集信息

Table 1 Information of three cluster datasets

数据集	记录数	特征数	类别
Iris	150	4	3
Wine	178	13	3
Seeds	210	7	3

图 4 (网络版彩图)Iris数据集算法进化曲线

Figure 4 (Color online) Algorithm evolution curve for Iris dataset.

法在初始时刻的寻优速度差别不大, 但SLPIO算法并未表现出优异性, 在迭代次数到达100次时, SLPIO算法进入地标算子阶段, 寻优能力进一步增强, 快速接近最优解, 最终稳定后的解明显优于其他两个算法。

对Iris数据的20次仿真进行数据统计, 如表2所示, SLPIO算法在最优值、平均值与计算时间上相比其他两个算法都表现出了优异性, 最优值相比基本PIO算法改善6.24%, 平均值改善4.43%, 虽增加自学习机制但并未增加计算时间, 图5对三个算法的数据进行了更清晰的对比。

4.2 Wine数据集对比验证

由表1可知, Wine数据集具有13个特征, 分为3类, 则转换到优化算法中, 变量维度为39。对每个算法进行无差别20次仿真取其最优结果, 结果如图6所示, 对于较高维度的优化问题, 三类算法在初始时刻的寻优速度就表现出了差异, SLPIO寻优速度较快且快速达到稳定值, PIO与PSO算法虽到达稳定状态的时间较短, 但算法的寻优能力较差。

对Wine数据的20次仿真进行数据统计, 如表3所示, LSPIO算法在最优值、平均值上相比其他两个算法都表现出了优异性, 但最优解改进程度并不明显, 时间相比PIO算法略有增加, 说明随着维度的增加, 自

表 2 Iris数据集对比试验数据

Table 2 Comparative test data of Iris dataset

算法	最优值	平均值	计算时间
PSO	276.0957	314.2498	25.0379
PIO	264.8901	309.4952	12.3649
SLPIO	248.3613	295.7985	12.0867

图 5 (网络版彩图)Iris数据集算法仿真数据对比

Figure 5 (Color online) Comparison of simulation data for Iris dataset.

图 6 (网络版彩图)Wine数据集算法进化曲线
Figure 6 (Color online) Algorithm evolution curve for Wine dataset.

表 3 Wine数据集对比试验数据

Table 3 Comparative test data of Wine dataset

算法	最优值	平均值	计算时间
PSO	352220	352323	27.9010
PIO	352180	352259	23.0676
SLPIO	352140	352238	29.3478

学习机制需要更多的寻优时间, 图7对三个算法的数据进行了更清晰的对比。

4.3 Seeds数据集对比验证

由表1可知, Seeds数据集具有7个特征, 分为3类, 则转换到优化算法中, 变量维度为21. 对每个算法进行无差别20次仿真取其最优结果, 结果如图8所示, 同样三类算法在初始时刻的寻优速度就表现出了差异,

图 7 (网络版彩图)Wine数据集算法仿真数据对比
Figure 7 (Color online) Comparison of simulation data for Wine dataset.

图 8 (网络版彩图)Seeds数据集算法进化曲线
Figure 8 (Color online) Algorithm evolution curve for Seeds dataset.

表 4 Seeds数据集对比试验数据

Table 4 Comparative test data of Seeds dataset

算法	最优值	平均值	计算时间
PSO	1849.2	2159.15	49.3635
PIO	1670.1	2021.52	25.8849
SLPIO	1516.9	1977.69	49.6813

SLPIO寻优速度较快且快速达到稳定值, PIO与PSO算法虽到达稳定状态的时间较短, 但算法的寻优能力相比改进后的SLPIO较差。

对Seeds数据的20次仿真进行数据统计, 如表4所示, SLPIO算法在最优值、平均值上相比其他两个算法都表现出了优异性, 最优值相比基本PIO算法改善9.17%, 平均值改善2.17%, 高维度的寻优使得自学习机制相比PIO算法耗费更多计算时间, 图9对三个算法

图 9 (网络版彩图)Seeds数据集算法仿真数据对比
Figure 9 (Color online) Comparison of simulation data for Seeds dataset.

的数据进行了更清晰的对比.

5 讨论与结论

针对大规模无人机集群系统的分组聚类需求, 在有限交互范围条件下, 本文提出基于鸽群智能行为的无人机集群聚类优化算法, 基于聚类目的对鸽群优化算法进行设计, 对变量进行转换, 并设计适应度函数; 基于鸽群智能行为, 对鸽群飞行过程中的层级网络机制进行研究, 将其映射到鸽群优化算法的自学习机制中. 一方面, 来自临近个体的引导对于鸽子的飞行更为直接有效, 因而有限交互范围内的优异个体对于鸽子导航的引导更快速直接, 这使得改进后的算法计算

时间并未大幅度提升. 另一方面, 鸽群的中心位置更新由三部分组成: 增量惯性部分、模仿部分、环境影响部分, 其中增量惯性部分继承上一时刻的中心位置更新, 模仿部分向交互范围内的最优信息学习, 环境影响部分跟随邻居个体的整体趋势进行移动. 这使得鸽子的个体位置更新具有更好的探索能力, 避免陷入局部最优解.

为验证改进后鸽群优化算法在有限交互范围下的有效性, 本文采用三种算法针对三个数据集进行聚类分组. 仿真结果与数据可表明改进后的鸽群优化算法在最优解与平均最优解上均有较大的改善, 且计算时间仍然较短, 具有较好的扩展性和实用性, 为战场环境下的大规模无人机集群聚类分组提供了可行的方法.

参考文献

- 1 Luo D L, Xu Y, Zhang J P. New progresses on UAV swarm confrontation (in Chinese). *Sci Tech Rev*, 2017, 35: 26–31 [罗德林, 徐扬, 张金鹏. 无人机集群对抗技术新进展. *科技导报*, 2017, 35: 26–31]
- 2 Kennedy J, Eberhart R C. *Swarm Intelligence*. Cambridge: Academic Press, 2001
- 3 Bonabeau E, Dorigo M, Theraulaz G. Inspiration for optimization from social insect behaviour. *Nature*, 2000, 406: 39–42
- 4 Bonabeau E, Dorigo M, Theraulaz G. *Swarm Intelligence from Nature to Artificial Systems*. New York: Oxford University Press, 1999
- 5 Duan H B, Qiu H X. *Unmanned Aerial Vehicle Swarm Autonomous Control Based on Swarm Intelligence* (in Chinese). Beijing: Science Press, 2018 [段海滨, 邱华鑫. 基于群体智能的无人机集群自主控制. 北京: 科学出版社, 2018]
- 6 Duan H B, Huo M Z, Fan Y M. Flight verification of multiple UAVs collaborative air combat imitating the intelligent behavior in hawks (in Chinese). *Control Theory Appl*, 2018, 35: 1812–1819 [段海滨, 霍梦真, 范彦铭. 仿鹰群智能的无人机集群协同对抗飞行验证. *控制理论与应用*, 2018, 35: 1812–1819]
- 7 Duan H B, Li P. Autonomous control for unmanned aerial vehicle swarms based on biological collective behaviors (in Chinese). *Sci Tech Rev*, 2017, 35: 19–27 [段海滨, 李沛. 基于生物群集行为的无人机集群控制. *科技导报*, 2017, 35: 19–27]
- 8 Guilford T, Roberts S, Biro D, et al. Positional entropy during pigeon homing II: Navigational interpretation of Bayesian latent state models. *J Theor Biol*, 2004, 227: 25–38
- 9 Mora C V, Davison M, Martin Wild J, et al. Magnetoreception and its trigeminal mediation in the homing pigeon. *Nature*, 2004, 432: 508–511
- 10 Whiten A. Operant study of sun altitude and pigeon navigation. *Nature*, 1972, 237: 405–406
- 11 Duan H B, Qiao P X. Pigeon-inspired optimization: A new swarm intelligence optimizer for air robot path planning. *Int Jnl Intel Comp Cyber*, 2014, 7: 24–37
- 12 Xu X B, Deng Y M. UAV power component—DC brushless motor design with merging adjacent-disturbances and integrated-dispatching pigeon-inspired optimization. *IEEE Trans Magn*, 2018, 54: 1–7
- 13 Zhang B, Duan H B. Three-dimensional path planning for uninhabited combat aerial vehicle based on predator-prey pigeon-inspired optimization in dynamic environment. *IEEE/ACM Trans Comput Biol Bioinf*, 2017, 14: 97–107
- 14 Duan H B, Wang X H. Echo state networks with orthogonal pigeon-inspired optimization for image restoration. *IEEE Trans Neural Netw Learning Syst*, 2016, 27: 2413–2425
- 15 Nagy M, Akos Z, Biro D, et al. Hierarchical group dynamics in pigeon flocks. *Nature*, 2010, 464: 890–893
- 16 Nagy M, Vászárhelyi G, Pettit B, et al. Context-dependent hierarchies in pigeons. *Proc Natl Acad Sci USA*, 2013, 110: 13049–13054
- 17 Qiu H X, Duan H B, Fan Y M. Multiple unmanned aerial vehicle autonomous formation based on the behavior mechanism in pigeon flocks (in Chinese). *Control Theory Appl*, 2015, 32: 1298–1304 [邱华鑫, 段海滨, 范彦铭. 基于鸽群行为机制的多无人机自主编队. *控制理论与应用*,

2015, 32: 1298–1304]

- 18 Cheng R, Jin Y C. Demonstrator selection in a social learning particle swarm optimizer. In: 2014 IEEE Congress on Evolutionary Computation (CEC). Beijing, 2014. 3103–3110

Clustering optimization algorithm for large-scale unmanned aerial vehicle based on intelligent behavior of pigeons

HUO MengZhen, WEI Chen, YU YuePing & ZHAO JianXia

Bio-inspired Autonomous Flight Systems Research Group, School of Automation Science and Electrical Engineering, Beihang University, Beijing 100083, China

In future air battlefield, clusters of large-scale unmanned aerial vehicle (UAV) will become the dominant force. The effective grouping and clustering of large-scale UAV cluster systems are necessary steps to complete combat tasks. Due to the limited communication constraints in the battlefield, UAVs cannot obtain comprehensive and effective global combat information. Thus, this paper proposed a large-scale UAV clustering optimization algorithm based on the intelligent behavior of pigeons. Also, this paper studied and analyzed the intelligent behavior of the flock of pigeons with excellent navigation ability and mapped the hierarchical network mechanism in the flight process of the pigeon flock into the pigeon-inspired optimization (PIO) algorithm. Hence, it solved the problem of incomplete information in a limited interactive environment. On one hand, it is more effective and direct to guide the pigeon flock from adjacent individuals during flight. Therefore, under the limited interaction condition, the global optimal information of the basic PIO algorithm is replaced by the optimal individual information within the interaction range. On the other hand, the central position renewal of the pigeon flock consists of three parts: inertia part, imitation part, and environmental impact part. In order to verify the effectiveness of the improved PIO algorithm in a limited interactive range, this paper adopted three algorithms to cluster three datasets. Simulation results reveal that the improved PIO algorithm achieved significant improvement in the optimal solution and the average optimal solution; notably, the computation time does not increase significantly, thus providing an effective solution for the clustering of UAV cluster systems in the actual combat environment.

unmanned aerial vehicle (UAV) cluster, clustering group, flock intelligent behavior, pigeon-inspired optimization algorithm

doi: [10.1360/SST-2019-0317](https://doi.org/10.1360/SST-2019-0317)