

## 多无人船通信网络拓扑优化控制算法

崔亚妮<sup>1</sup>, 任佳<sup>1,2†</sup>, 杜文才<sup>1,2</sup>, SHIKHIN Vladimir<sup>3</sup>

(1. 海南大学 信息科学技术学院, 海南 海口 570228;

2. 海南大学 南海海洋资源利用国家重点实验室, 海南 海口 570228;

3. 莫斯科动力学院 自动化与计算机工程学院, 俄罗斯 莫斯科 111250)

**摘要:** 为构建有效、可靠的多无人船网络拓扑结构, 本文提出一种基于改进粒子群优化的多无人船网络拓扑优化控制算法. 该算法通过综合考虑网络连通度、链路通信质量、网络连接收益和网络连接成本构建多无人船网络拓扑优化模型. 为确保模型与应用对象的适配性, 重点分析海上无线电波的传播特性, 并在此基础上, 完成链路通信质量、网络连接收益和网络连接成本的表征. 为获得模型的全局最优解, 加快模型的收敛速度, 在粒子群优化算法的迭代寻优过程中, 借鉴电磁场中带电粒子间的相互作用, 利用粒子的电荷量动态自适应调整算法的控制参数, 当粒子种群多样性小于给定的阈值时, 将粒子种群中适应度值最小的粒子作为扰动粒子, 引导粒子向未搜索区域移动, 克服算法的早熟收敛. 仿真结果证明了该算法的有效性.

**关键词:** 无人船; 拓扑优化; 电波传播; 类电磁机制; 粒子群优化

中图分类号: TP181 文献标识码: A

## Network topology optimization control algorithm for multiple unmanned surface vehicle

CUI Ya-ni<sup>1</sup>, REN Jia<sup>1,2†</sup>, DU Wen-cai<sup>1,2</sup>, SHIKHIN Vladimir<sup>3</sup>

(1. College of Information Sciences & Technology, Hainan University, Haikou Hainan 570228 China;

2. State Key Laboratory of Marine Resource Utilization in South China Sea, Hainan University, Haikou Hainan 570228 China;

3. Department of Automation and Computer Engineering, Moscow Power Engineering Institute, Moscow 111250 Russia)

**Abstract:** In order to construct an efficient and reliable network topology, a topology optimization control algorithm based on improved particle swarm optimization is proposed. And the network topology optimization model of multiple USV (unmanned surface vehicle) is constructed by considering the network connectivity, the link communication quality, the earnings and the cost of network connection. In order to ensure the suitability between the model and the application object, maritime radio propagation characteristics are analyzed, and on this basis, the representation of the link communication quality, the earnings and the cost of network connection are obtained. To get the globally optimal solution and accelerate the convergence of the model, in the iterative optimization process of particle swarm optimization algorithm, considering the interaction between charged particles in electromagnetic field, using the charge quantity of the particle dynamically adaptive adjust the control parameters. When the diversity of particle swarm is less than the given threshold, the particle owning the smallest fitness value in the swarm will be regarded as the disturbing particle to guide the swarm to the region which has not been searched, to overcome the premature convergence of the algorithm. Simulation results demonstrate the effectiveness of the proposed algorithm.

**Key words:** unmanned surface vehicle; topology optimization; radio propagation; electromagnetism-like mechanism; particle swarm optimization

### 1 引言(Introduction)

作为水面智能体的典型代表, 无人船 (unmanned surface vehicles, USV) 可完成水面和水下目标侦

察、搜索和监视等任务<sup>[1]</sup>. 受尺寸、载荷和船载设备等因素影响, 单艘USV难以满足大范围海区和多任务作业要求, 需要通过多USV协同完成.

收稿日期: 2016-06-30; 录用日期: 2016-12-22.

†通信作者. E-mail: renjia@hainu.edu.cn.

本文责任编辑: 孙长银.

国家国际科技合作专项(2015DFR10510), 国家自然科学基金项目(61562018), 海南省高等学校科学研究项目(HNKY2014-04)资助.

Supported by International S&T Cooperation Projects of China (2015DFR10510), National Natural Science Foundation of China (61562018) and Scientific Research Program of the Higher Education Institutions of Hainan Province, China (HNKY2014-04).

稳定、可靠的网络拓扑结构是多USV协同作业的前提。网络拓扑结构的优化控制是一种典型的离散组合优化过程,属于NP难问题。为此,学者们将多种智能优化算法运用于网络拓扑优化控制,主要包括:蚁群优化(ant colony optimization, ACO)算法<sup>[2]</sup>,遗传算法(genetic algorithm, GA)<sup>[3]</sup>,模拟退火(simulated annealing, SA)算法<sup>[4]</sup>,粒子群优化(particle swarm optimization, PSO)算法<sup>[5-6]</sup>等。相较于其它智能优化算法,PSO算法具有收敛速度快、算法复杂度低、控制参数少、简单易实现等特点<sup>[7]</sup>,在网络拓扑优化控制领域获得了广泛应用。如:文献[8]综合考虑节点的移动性、剩余能量、节点度等特征,利用PSO算法完成了网络的拓扑优化控制,提高了网络的生命周期;文献[9]在链路容量和网络全连通约束下,以最大化网络流量作为PSO算法的目标函数,实现了对节点状态的控制;文献[10]综合考虑距离、节点度、剩余能量等因素构建PSO算法的适应度函数,完成了网络的分簇拓扑结构优化。但上述算法都是直接利用连续PSO算法进行求解,将获得的连续解进行取整运算,易出现多个连续解对应一个整数解的情况,无法保证网络拓扑连接的最优。文献[11]综合考虑网络通信时延、跳数、优化成本等因素构建网络拓扑优化控制模型,并利用模糊逻辑将模型的多目标优化问题转化成单目标优化问题,在此基础上,利用离散粒子群优化(discrete particle swarm optimization, DPSO)算法实现了网络的拓扑优化控制。但粒子更新过程采用静态权重,算法的自适应能力较差;文献[12]利用DPSO算法实现了网络的拓扑优化控制,且粒子更新过程采用动态权重,但其权重的更新只依赖于算法的迭代次数,而与粒子自身进化的状态没有关系。此外,上述文献在利用DPSO算法实现网络的拓扑优化控制时,都是考虑节点的剩余能量、通信时延等因素构建网络拓扑优化控制模型,然后利用DPSO算法对模型进行求解。而无线电波的传播特征直接决定了通信时延、节点能耗等网络参数的性能。受地球曲率以及风、海浪、海水电导率和介电常数不恒定等不确定因素的影响,海上无线电波传播环境瞬息万变,使得海上无线电波传播特征与陆地无线电波传播特征差异较大,若不考虑海上无线电波传播特征,而将上述算法直接应用于多USV网络中,可能会导致算法的有效性下降。

为实现多USV网络的拓扑优化控制,本文在海上无线电波传播特性的基础上,综合考虑链路通信质量、网络连通度、网络连接收益和网络连接成本构建多USV网络拓扑优化控制模型,确保该模型与应用对象的适配性。为获得该模型的全局最优解,加快模型收敛速度,在场域理论下,借鉴电磁场中带电粒子间的相互作用,提出一种基于类电磁机制的DPSO算法,实现多USV网络的拓扑优化控制。

## 2 多USV网络拓扑优化控制模型(Network topology optimization control model for multi-USV)

在构建的多USV网络拓扑优化控制模型中,综合考虑链路通信质量、网络连通度、网络连接收益和网络连接成本等因素,以实现网络连接增益(网络连接收益与网络连接成本的比值)的最大化。即构建的多USV网络拓扑优化控制模型可表示为

$$\max \frac{f(P)}{f(C)}, \quad (1)$$

其中

$$\begin{cases} f(P) = \frac{P - P_{\min}}{P_{\max} - P_{\min}}, \\ f(C) = \frac{C_{\max} - C_{\min}}{C_{\max} - C}, \end{cases} \quad (2)$$

式中:  $f(P)$ 表示网络连接收益函数,  $f(C)$ 表示网络连接成本函数,  $\frac{f(P)}{f(C)}$ 表示网络连接增益;  $P$ 表示网络连接收益,它受链路通信质量 $Q_e$ 的约束;  $P_{\max}$ ,  $P_{\min}$ 分别表示网络连接收益的最大值和最小值;  $C$ 表示网络连接成本,  $C_{\max}$ ,  $C_{\min}$ 分别表示网络连接成本的最大值和最小值。

### 2.1 海上无线链路通信质量模型(Maritime wireless link communication quality model)

常用的链路通信质量评价指标有收包率、链路质量指示以及接收信号强度指示等。其中,收包率是最能明确反映链路通信质量的指标,但不能实时获得,而链路的路径损耗与收包率之间是一一对应的,能够较好地反映收包率的变化<sup>[13]</sup>。为此,选用路径损耗作为链路通信质量的评价指标。




图1 海上无线电波的传播路径示意图

Fig. 1 Maritime radio propagation path

为获得USV间信号传播的路径损耗,需要对海上无线电波的传播路径进行建模。受海浪、地形、地球曲率以及USV自身运动的影响,USV间的信号传播路径是包括直射径、反射径、散射径等各种传播路径的随机组合。当收发端在可视距离内时,接收信号主要是直射径和反射径的组合;当收发端在可视距离以外

时, 还需要额外考虑由地球球面遮挡而造成的绕射损耗<sup>[14]</sup>. 海上无线电波的传播路径如图1所示.

如图1所示, 海上无线电波的传播损耗根据传播距离分为3段: ① A段: 从发射端 $T$ 到发射端可视距离点 $R_A$ , 距离为 $d_1$ ; ② B段: 从发射端可视距离点 $R_A$ 到发射端和接收端合并的可视距离点 $R_B$ , 距离为 $d_2$ ; ③ C段: 超过发射端和接收端合并的可视距离点 $R_B$ 范围的地球阴影区域, 距离为 $d_3$ . 其传播损耗模型如式(3)所示.

$$\begin{cases} L_A = 32.44 + 20 \lg f + 10\gamma \lg d, & d \leq d_1, \\ L_B = L_A + 6(d - d_1)/d_2, & d_1 < d \leq d_1 + d_2, \\ L_C = L_A + \text{Dif}f_C, & d > d_1 + d_2, \end{cases} \quad (3)$$

式中:  $L_A, L_B, L_C$ 分别表示A段, B段, C段的传播损耗, 单位为dB;  $f$ 表示频率, 单位为MHz;  $d$ 表示传播距离, 单位为km;  $\gamma$ 表示路径损耗因子, 一般取值范围为2~5;  $\text{Dif}f_C$ 表示修正的绕射传播损耗, 如式(4)所示.

$$\text{Dif}f_C = 20 \lg [0.5e^{(0.45-0.62v)v}], \quad (4)$$

其中

$$\begin{cases} v = -R_e [1 - \sin(\alpha + \beta) / (\sin \alpha + \sin \beta)] \times \\ \sqrt{\frac{2d}{\lambda(d_1 + d_2)[d - (d_1 + d_2)]}}, \\ \alpha = (d_1 + d_2) / R_e, \\ \beta = [d - (d_1 + d_2)] / R_e, \end{cases} \quad (5)$$

式中:  $R_e$ 表示地球等效半径, 单位为km;  $\alpha, \beta$ 表示对应修正地球模型的夹角, 单位为rad;  $\lambda$ 表示波长, 单位为km.

根据获得的路径损耗, 计算链路 $e_{ij}$ 的通信质量 $Q_{-e_{ij}}$ .

$$Q_{-e_{ij}} = \frac{L_{\max} - L_{ij}}{L_{\max} - L_{\min}}, \quad \forall (i, j) \in \mathbb{N} \times \mathbb{N}, \quad (6)$$

式中:  $\mathbb{N} = \{1, 2, \dots, n\}$ 表示USV集合;  $\mathbf{E} = \{e_{ij} | i, j \in \mathbb{N}\}$ 表示USV间的链路集合;  $L_{ij}$ 表示链路 $e_{ij}$ 的路径损耗, 由式(3)获得;  $L_{\max}, L_{\min}$ 分别表示链路路径损耗的最大值和最小值.

为验证海上无线电波传播特性与陆地无线电波传播特征的区别, 在海南省三亚市三亚湾开展海上无线电波传播特征的测试, 并利用自由空间传播损耗预测模型、Okumura-Hata传播损耗预测模型和海上无线电波传播损耗预测模型与实测数据进行匹配, 其结果如图2所示.

由图2可知, 海上无线电波传播损耗预测模型与实测数据最为吻合, 自由空间传播损耗预测模型和Okumura-Hata传播损耗预测模型与实测数据相差较

大. 海上无线电波传播特性与陆地无线电波传播特征区别较大. 复杂多变的海上无线电波传播环境使得USV间的无线链路存在易变、不稳定的特点, 从而降低多USV网络拓扑的可靠性和连通性. 因此, 在多USV网络拓扑优化控制过程中, 必须考虑海上无线电波的传播特性, 不能忽略其对网络拓扑优化控制的影响. 基于此, 本文在多USV网络的拓扑优化控制过程中, 充分考虑海上无线电波的传播特性, 并在此基础上, 构建多USV网络拓扑优化控制模型.




图2 海上无线电波传播损耗

Fig. 2 Path loss of maritime radio propagation

## 2.2 多USV网络连接收益模型(Network connection earning model for multi-USV)

USV间的链路连接收益大小与链路的重要度相关, 链路的重要度越大, 该链路连接的价值就越高, 连接收益也就越大. 因此, 多USV网络连接收益模型可表征为

$$P = \sum_{i=1}^n \sum_{j=1, j \neq i}^n x_{-e_{ij}} \cdot I_{-e_{ij}}, \quad (7)$$

式中:  $P$ 表示网络连接收益;  $x_{-e_{ij}}$ 表示链路 $e_{ij}$ 是否连接, 如果连接, 则 $x_{-e_{ij}} = 1$ , 否则 $x_{-e_{ij}} = 0$ ;  $I_{-e_{ij}}$ 表示链路 $e_{ij}$ 的重要度, 它受链路通信质量 $Q_{-e_{ij}}$ 的约束, 如式(8)所示.

$$I_{-e_{ij}} = \begin{cases} \frac{I_i \cdot I_j}{I_i + I_j}, & Q_{-e_{ij}} \geq Q_{-e_{th}}, \\ 0, & Q_{-e_{ij}} < Q_{-e_{th}}, \end{cases} \quad (8)$$

式中:  $Q_{-e_{ij}}$ 表示链路 $e_{ij}$ 的通信质量, 由式(6)获得;  $Q_{-e_{th}}$ 表示链路通信质量门限;  $I_i, I_j$ 分别表示UAV $_i$ 和UAV $_j$ 的节点重要度, 它与节点度和节点效率相关, 如式(9)所示.

$$I_i = \eta_1 D_i + \eta_2 E_i, \quad (9)$$

式中:  $\eta_1, \eta_2$ 表示加权因子,  $\eta_1 + \eta_2 = 1$ ;  $D_i$ 表示UAV $_i$ 的节点度, 是指与UAV $_i$ 直接相连的USV数目;  $E_i$ 表示UAV $_i$ 的节点效率, 是指UAV $_i$ 与其它USV间路径长度倒数的平均值, 表征了该节点到其它节点的平均难易程度, 节点效率越高, 该节点向其它节点传输信息

就越容易、传输时延就越小,传输速率就越高,如式(10)所示.

$$E_i = \frac{1}{n-1} \sum_{j=1, j \neq i}^n \frac{1}{p_{ij}}, \quad (10)$$

式中:  $n$ 表示USV的数量;  $p_{ij}$ 表示UAV $_i$ 和UAV $_j$ 间的路径长度,定义为连接UAV $_i$ 和UAV $_j$ 间的最短路径的权值之和,如式(11)所示.

$$p_{ij} = \min_{e_{pq} \in \theta_{i,j}} \sum \varphi_{pq}, \quad (11)$$

式中:  $\theta_{i,j}$ 表示连接UAV $_i$ 和UAV $_j$ 的路径集合,  $e_{pq}$ 表示连接UAV $_i$ 和UAV $_j$ 的某条路径的组成边,  $\varphi_{pq}$ 表示边 $e_{pq}$ 的权值,与链路通信质量 $Q_{-e_{pq}}$ 有关,如式(12)所示:

$$\varphi_{pq} = \begin{cases} \varepsilon \cdot Q_{-e_{pq}}, & Q_{-e_{pq}} \geq Q_{-e_{th}}, \\ \infty, & Q_{-e_{pq}} < Q_{-e_{th}}. \end{cases} \quad (12)$$

### 2.3 多USV网络连接成本模型(Network connection cost model for multi-USV)

USV间的链路连接成本不仅与链路的路径长度有关,还与链路的类型有关,链路的类型包括必需边和冗余边两种,且必需边的连接成本小于冗余边的连接成本.因此,多USV网络连接成本模型可表征为

$$C = \sum_{i=1}^n \sum_{j=1, j \neq i}^n x_{-e_{ij}} \cdot C_{ij}, \quad (13)$$

式中:  $C$ 表示网络连接成本;  $C_{ij}$ 表示链路 $e_{ij}$ 的连接成本,如式(14)所示.

$$C_{ij} = \begin{cases} \delta_1 \cdot C_0 \cdot \varphi_{ij}, & \varphi_{ij} < p_{ij}, \\ \delta_2 \cdot C_0 \cdot \varphi_{ij}, & \varphi_{ij} \geq p_{ij}, \\ 0, & \varphi_{ij} = \infty, \end{cases} \quad (14)$$

式中:  $C_0$ 表示连接单位长度无线链路所需要的连接成本;  $\varphi_{ij}$ ,  $p_{ij}$ 分别表示链路 $e_{ij}$ 的权值和路径长度;  $\delta_1$ ,  $\delta_2$ 表示链路连接成本的加权因子,且 $\delta_1 < \delta_2$ .

## 3 基于EM-DPSO的多USV网络拓扑优化控制算法 (Multi-USV network topology optimization algorithm based on EM-DPSO)

### 3.1 基于DPSO的多USV网络拓扑优化控制算法 (Multi-USV network topology optimization algorithm based on DPSO)

多USV网络的拓扑优化控制是一种典型的离散组合优化问题,不能直接运用连续PSO算法对该问题求解,需要对其进行离散化处理.常用的离散化策略有3种:将速度作为位置变化的概率,直接将连续PSO用于离散问题的求解,重新定义算法运算操作.本文采用第3种策略,对PSO算法的更新公式进行重新定义,获得DPSO算法的速度和位置更新公式,其更新公式如下:

$$V_s^{t+1} = \omega \otimes V_s^t \oplus \omega_1 \otimes (X_s^t \ominus P_s^t) \oplus$$

$$\omega_2 \otimes (X_s^t \ominus P_g^t), \quad (15)$$

$$X_s^{t+1} = X_s^t \odot V_s^{t+1}, \quad (16)$$

式中:  $V_s^t$ ,  $X_s^t$ 分别表示第 $t$ 次迭代中粒子 $s$ 的速度和位置;  $P_s^t$ 表示粒子 $s$ 的局部最佳位置,即

$$P_s^t = \text{optimal}\{X_s^1, X_s^2, \dots, X_s^t\};$$

$P_g^t$ 表示粒子种群 $S = \{1, 2, \dots, m\}$ (种群规模为 $m$ )的全局最佳位置,即

$$P_g^t = \text{optimal}\{P_1^t, \dots, P_s^t, \dots, P_m^t\};$$

$\omega, \omega_1, \omega_2$ 分别表示惯性权重,认知权重和社会权重.

式(15)中,粒子速度的更新包括3部分:第1部分是惯性部分,代表粒子当前所进行的惯性运动;第2部分是认知部分,代表粒子对自身历史经验的认知和继承度;第3部分表示社会部分,代表粒子对群体社会信息的共享和学习度.

根据多USV网络拓扑优化控制的实际特点,对运用DPSO算法求解该问题的粒子编码方式、更新方式及其相关运算操作进行如下说明.

·位置编码:  $X = \{e_{ij} | x_{-e_{ij}} = 1, i, j \in \mathbb{N}\}$ ,它是由若干条链路组成的集合.

·速度编码:  $V = \{e_{ij} \Leftrightarrow e_{i'j'} | i, j, i', j' \in \mathbb{N}\}$ ,其中,“ $\Leftrightarrow$ ”表示替换操作,“ $e_{ij} \Leftrightarrow e_{i'j'}$ ”表示用链路 $e_{i'j'}$ 替换链路 $e_{ij}$ ,所以 $V$ 是由若干个替换序列组成的集合,且 $|V| \leq V_{\max}$ , $|V|$ 表示速度集合的元素个数, $V_{\max}$ 表示粒子速度的最大范围,即粒子速度集合元素个数的最大值.

·实数与速度的乘法操作( $a \otimes V$ ):表示从 $V$ 中随机选取 $\lfloor a \times \text{length}(V) \rfloor$ 个元素组成的集合.

·速度与速度的加法操作( $V_1 \oplus V_2$ ):集合的并集操作,表示两个速度集合合并为一个速度集合.

·位置与位置的减法操作( $X_1 \ominus X_2$ ):表示粒子位置的变化量,即速度,所以 $X_1 \ominus X_2$ 也是由若干个替换序列组成的集合.

·位置与速度的加法操作( $X \odot V$ ):表示一种在替换操作( $\Leftrightarrow$ )基础上进行的加法操作,其结果为一个新的位置.

举例说明运用DPSO算法求解网络拓扑优化问题时粒子的更新方式.

假设USV的数量为6艘,第 $t$ 次迭代中粒子 $s$ 的特性参数如下所示:

$$\begin{cases} V_{\max} = 5, \omega = 0.72, \omega_1 = 0.375, \omega_2 = 0.26, \\ V_s^t = \{e_{12} \Leftrightarrow e_{23}, e_{15} \Leftrightarrow e_{24}, \\ \quad e_{35} \Leftrightarrow e_{45}, e_{46} \Leftrightarrow e_{56}\}, \\ X_s^t = \{e_{12}, e_{16}, e_{23}, e_{25}, e_{26}, e_{34}, e_{36}, e_{45}, e_{56}\}, \\ P_s^t = \{e_{12}, e_{15}, e_{16}, e_{25}, e_{26}, e_{34}, e_{36}, e_{45}, e_{56}\}, \\ P_g^t = \{e_{13}, e_{16}, e_{23}, e_{24}, e_{25}, e_{26}, e_{36}, e_{45}, e_{46}\}. \end{cases} \quad (17)$$

根据式(17)中粒子 $s$ 的位置 $\mathbf{X}_s^t$ 可知, 粒子 $s$ 所对应的网络拓扑结构如图3所示.




图 3  $\mathbf{X}_s^t$ 对应的网络拓扑结构图

Fig. 3 Network topology of  $\mathbf{X}_s^t$

根据式(17)中, 第 $t$ 次迭代中粒子 $s$ 的特性参数, 利用式(15)对粒子的速度进行更新.

首先, 计算速度更新的惯性部分. 由实数与速度的乘法操作定义可知, 从 $\mathbf{V}_s^t$ 中选取的元素个数为 $\lfloor 0.72 \times \text{length}(\mathbf{V}_s^t) \rfloor = \lfloor 0.72 \times 4 \rfloor = \lfloor 2.88 \rfloor = 2$ , 假设随机选取 $e_{12} \Leftrightarrow e_{23}$ 和 $e_{35} \Leftrightarrow e_{45}$ , 则 $\omega \otimes \mathbf{V}_s^t = \{e_{12} \Leftrightarrow e_{23}, e_{35} \Leftrightarrow e_{45}\}$ .

然后, 计算速度更新的认知部分. 由位置与位置的减法操作定义可知,  $\mathbf{X}_s^t \ominus \mathbf{P}_s^t = \{[\ ] \Leftrightarrow e_{15}, e_{23} \Leftrightarrow [\ ]\}$ , 这里 $[\ ] \Leftrightarrow e_{24}$ 表示增加边 $e_{24}$ ,  $e_{34} \Leftrightarrow [\ ]$ 表示删除边 $e_{34}$ . 从 $\mathbf{X}_s^t \ominus \mathbf{P}_s^t$ 中选取的元素个数为

$$\begin{aligned} \lfloor 0.375 \times \text{length}(\mathbf{X}_s^t \ominus \mathbf{P}_s^t) \rfloor &= \\ \lfloor 0.375 \times 2 \rfloor &= \lfloor 0.75 \rfloor = 0, \end{aligned}$$

故 $\omega_1 \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_s^t) = \{\}$ .

同理,  $\mathbf{X}_s^t \ominus \mathbf{P}_g^t = \{e_{12} \Leftrightarrow e_{13}, [\ ] \Leftrightarrow e_{24}, e_{34} \Leftrightarrow [\ ], e_{56} \Leftrightarrow e_{46}\}$ , 从 $\mathbf{X}_s^t \ominus \mathbf{P}_g^t$ 中选取的元素个数为 $\lfloor 0.26 \times \text{length}(\mathbf{X}_s^t \ominus \mathbf{P}_g^t) \rfloor = \lfloor 0.26 \times 4 \rfloor = \lfloor 1.04 \rfloor = 1$ , 假设随机选取 $e_{56} \Leftrightarrow e_{46}$ , 则 $\omega_2 \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_g^t) = \{e_{56} \Leftrightarrow e_{46}\}$ .

最后, 根据速度与速度的加法操作定义可得

$$\begin{aligned} \mathbf{V}_s^{t+1} &= \\ \{e_{12} \Leftrightarrow e_{23}, e_{35} \Leftrightarrow e_{45}\} \oplus \{\} \oplus \{e_{56} \Leftrightarrow e_{46}\} &= \\ \{e_{12} \Leftrightarrow e_{23}, e_{35} \Leftrightarrow e_{45}, e_{56} \Leftrightarrow e_{46}\}. \end{aligned} \quad (18)$$

由于 $|\mathbf{V}_s^{t+1}| = 3 < V_{\max} = 5$ , 所以第 $t+1$ 次迭代中粒子 $s$ 的速度更新为

$$\mathbf{V}_s^{t+1} = \{e_{12} \Leftrightarrow e_{23}, e_{35} \Leftrightarrow e_{45}, e_{56} \Leftrightarrow e_{46}\}. \quad (19)$$

在此基础上, 根据式(16)可知, 第 $t+1$ 次迭代中粒子 $s$ 的位置更新为

$$\begin{aligned} \mathbf{X}_s^{t+1} &= \\ \{e_{12}, e_{16}, e_{23}, e_{25}, e_{26}, e_{34}, e_{36}, e_{45}, e_{56}\} \odot \\ \{e_{12} \Leftrightarrow e_{23}, e_{35} \Leftrightarrow e_{45}, e_{56} \Leftrightarrow e_{46}\} &= \end{aligned}$$

$$\{e_{16}, e_{23}, e_{25}, e_{26}, e_{34}, e_{36}, e_{45}, e_{46}\}. \quad (20)$$

注意, 由于 $\mathbf{X}_s^t$ 中不存在 $e_{35}$ , 因此, 不需要执行 $e_{35} \Leftrightarrow e_{45}$ 操作, 只需执行 $e_{12} \Leftrightarrow e_{23}$ 和 $e_{56} \Leftrightarrow e_{46}$ 操作.

### 3.2 基于EM-DPSO的多USV网络拓扑优化控制算法(Multi-USV network topology optimization algorithm based on EM-DPSO)

由上述描述可知, DPSO算法可以对多USV网络的拓扑优化控制问题进行求解. 在DPSO算法中, 粒子更新的权重对算法的性能起着决定性作用<sup>[15]</sup>. 因此, 学者们对粒子更新的静态权重进行了改进, 提出了动态或自适应权重, 从而提高算法的性能<sup>[16-17]</sup>. 然而, 这些改进大都依赖于算法的迭代次数, 而与粒子自身进化的状态没有关系. 基于此, 本文提出一种基于类电磁机制的DPSO算法——EM-DPSO算法. 该算法将可行域中的每个粒子都看成是一个带电粒子, 并利用粒子的电荷量动态自适应更新权重, 提高算法的收敛速度和自适应能力; 同时, 借鉴带电粒子间的吸引-排斥机制, 当种群多样性小于阈值时, 在迭代过程中引入排斥策略, 克服算法的早熟收敛, 提高算法的全局搜索能力.

电磁场中带电粒子的电荷量越大, 该粒子对其它粒子的吸引力就越强. 在EM-DPSO算法中, 利用粒子的适应度值表征粒子的电荷量大小, 适应度值越大, 粒子的吸引力就越强, 粒子自身及其它粒子从该粒子继承信息的继承度就越高. 因此, 定义第 $t$ 次迭代中粒子 $s$ 速度更新的自适应权重公式为

$$\begin{cases} \omega_s^t = q_s^t, \\ \omega_{1s}^t = q_s^t \times q_{P_s}^t, \\ \omega_{2s}^t = q_s^t \times q_{P_g}^t, \end{cases} \quad (21)$$

式中:  $\omega_s^t, \omega_{1s}^t, \omega_{2s}^t$ 分别表示第 $t$ 次迭代中粒子 $s$ 的惯性权重、认知权重和社会权重;  $q_s^t, q_{P_s}^t, q_{P_g}^t$ 分别表示第 $t$ 次迭代中粒子 $s$ 的电荷量、粒子 $s$ 局部最佳粒子 $P_s$ 的电荷量和粒子种群全局最佳粒子 $P_g$ 的电荷量, 如式(22)所示.

$$q_s^t = \exp\left(-s_d \frac{\text{fit}(\mathbf{P}_g^t) - \text{fit}(\mathbf{X}_s^t)}{\sum_{s=1}^m (\text{fit}(\mathbf{P}_g^t) - \text{fit}(\mathbf{X}_s^t))}\right), \quad (22)$$

$$s = 1, 2, \dots, m,$$

式中:  $s_d$ 表示粒子 $s$ 的维度;  $\text{fit}(\mathbf{X}_s^t)$ 表示第 $t$ 次迭代中粒子 $s$ 的适应度值, 即网络连接增益值;  $\text{fit}(\mathbf{P}_g^t)$ 表示粒子种群全局最佳粒子的适应度值.

为避免算法在迭代过程中陷入局部最优, 在算法的迭代寻优过程中, 当种群多样性小于给定的阈值 $\text{div}_{\text{th}}$ 时, 利用粒子种群中适应度值最小的粒子作为扰动粒子, 利用排斥力引导粒子向未搜索区域移动, 克服算法的早熟收敛, 提高算法的全局搜索能力.

本文采用文献[18]中关于粒子种群多样性的定义,

其表达式如式(23)所示.

$$\text{div} = \frac{1}{m} \sum_{s=1}^m \text{div}_s. \quad (23)$$

式中:  $m$ 表示粒子种群规模;  $\text{div}$ 表示粒子种群多样性;  $\text{div}_s$ 表示粒子 $s$ 的个体多样性,是指粒子 $s$ ,粒子 $s$ 自身局部最佳粒子 $P_s$ 以及粒子种群全局最佳粒子 $P_g$ 之间的相异程度,如式(24)所示.

$$\text{div}_s = 1 - \frac{1}{3}(\text{simi}_{s,P_s} + \text{simi}_{s,P_g} + \text{simi}_{P_s,P_g}), \quad (24)$$

式中,  $\text{simi}_{s,k}$ 表示粒子 $s$ 与粒子 $k$ 之间的相异程度,由式(25)获得.

$$\begin{aligned} \text{simi}_{s,k} &= \frac{1}{S_d} \sum_{r=1}^{S_d} \text{dif}(x_{s,r} == x_{k,r}), \\ \text{dif}(x) &= \begin{cases} 1, & x = 1, \\ 0, & x = 0. \end{cases} \end{aligned} \quad (25)$$

根据上述描述,基于EM-DPSO的多USV网络拓扑优化控制算法的粒子速度更新公式可表示为

$$\mathbf{V}_s^{t+1} = \begin{cases} q_s^t \otimes \mathbf{V}_s^t \oplus (q_s^t \times q_{P_s}^t) \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_s^t) \oplus (q_s^t \times q_{P_g}^t) \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_g^t), & \text{div} \geq \text{div}_{\text{th}}, \\ q_s^t \otimes \mathbf{V}_s^t \oplus (q_s^t \times q_{P_s}^t) \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_s^t) \oplus (q_s^t \times q_{P_g}^t) \otimes (\mathbf{X}_s^t \ominus \mathbf{P}_g^t) \oplus (2 \times q_s^t \times q_{P_w}^t) \otimes (\mathbf{X}_s^t \ominus \mathbf{X}_{P_w}^t), & \text{div} < \text{div}_{\text{th}}. \end{cases} \quad (26)$$

式中:  $P_w$ 表示粒子种群中适应度值最小的粒子;  $\mathbf{X}_{P_w}^t, q_{P_w}^t$ 分别表示粒子 $P_w$ 的位置和电荷量.

### 3.3 基于EM-DPSO的多USV网络拓扑优化控制算法的实现(The implementation of multi-USV network topology optimization algorithm based on EM-DPSO)

根据上述算法描述,基于EM-DPSO的多USV网络拓扑优化控制主要通过以下8个步骤实现,伪代码如表1所示.

表 1 基于EM-DPSO的多USV网络拓扑优化控制算法伪代码

Table 1 Pseudo-code of Multi-USV network topology optimization algorithm based on EM-DPSO

程序变量集合( $s, t, t_{\max}, Y_{-s}, r_{-s}, r_{-s\max}, m, V_{\max}, \text{optglobal\_Parswarm}$ )
输入变量: $s$ —粒子序列号; $t$ —当前的迭代次数; $t_{\max}$ —最大迭代次数; $Y_{-s}$ —粒子 $s$ 是可行解; $r_{-s}$ —粒子 $s$ 不是可行解的次数; $r_{-s\max}$ —粒子 $s$ 不是可行解,重新更新的最大次数; $m$ —粒子种群规模; $V_{\max}$ —粒子速度更新的最大范围,即粒子速度集合元素个数的最大值;
输出变量: $\text{optglobal\_Parswarm}$ —粒子种群的全局最佳粒子.
1) for $t = 1 : t_{\max}$
2) if $t = 1$
3) Parswarm(:, 1)←在网络连通度和链路备选集约束下,实现粒子种群的初始化;
4) optglobal_Parswarm←根据Parswarm(:, 1),获得当前粒子种群的全局最佳粒子optglobal_Parswarm;
5) else
6) div←根据式(23)–(25)计算粒子种群多样性值;
7) for $s = 1 : m$
8) for $r_{-s} = 0 : r_{-s\max} - 1$
9) $ \mathbf{V}_s^{t+1} $ ←在网络连通度、链路备选集和种群多样性值的约束下,更新粒子 $s$ 的速度 $\mathbf{V}_s^{t+1}$ ;
10) if $ \mathbf{V}_s^{t+1}  > V_{\max}$ ,
11) $\mathbf{V}_s^{t+1}$ ←从 $\mathbf{V}_s^{t+1}$ 随机选取 $V_{\max}$ 个元素,重新更新 $\mathbf{V}_s^{t+1}$ ;
12) end if
13) $\mathbf{X}_s^{t+1}$ ←更新粒子 $s$ 的位置;
14) if $Y_{-s} = 1$ ←粒子 $s$ 是可行解;
15) Parswarm( $s, t + 1$ )←更新粒子 $s$ ;
16) break
17) end if
18) end for
19) Parswarm( $s, t + 1$ ) = Parswarm( $s, t$ )←粒子 $s$ 不更新,保持不变;
20) end for
21) optglobal_Parswarm←根据Parswarm( $s, t + 1$ ),更新粒子种群的全局最佳粒子optglobal_Parswarm;
22) end if
23) end for

**步骤 1** UAV<sub>i</sub>根据自身与UAV<sub>j</sub>间的距离,利用式(3)计算链路的路径损耗 $L_{ij}$ ,根据式(6)计算链路的通信质量 $Q_{e,ij}$ ,根据式(12)计算链路的权值 $\varphi_{ij}$ ;

**步骤 2** 根据链路通信质量门限 $Q_{e,th}$ 过滤网络拓扑,将链路通信质量小于 $Q_{e,th}$ 的链路删除,获得网络拓扑连接的链路备选集合 $C_e$ ;

**步骤 3** 初始化粒子种群,在网络连通度 $K$ 和链路备选集合 $C_e$ 的约束下,按照粒子编码方式随机产生 $m$ 个粒子的位置 $\mathbf{X}_s^1$ 和速度 $\mathbf{V}_s^1$ ;在此基础上,根据式(1)计算各个粒子的适应度值 $fit(\mathbf{X}_s^1)$ (即网络连接增益值),进而确定各个粒子自身的局部最佳位置 $\mathbf{P}_s^1$ 和适应度值 $fit(\mathbf{P}_s^1)$ 以及粒子种群的全局最佳位置 $\mathbf{P}_g^1$ 和适应度值 $fit(\mathbf{P}_g^1)$ ;

**步骤 4** 根据式(23)–(25)计算粒子种群多样性 $div$ ;

**步骤 5** 根据式(22)计算粒子的电荷量 $q_s^t$ ,在此基础上,根据式(21)计算粒子速度更新的惯性权重 $\omega_{1s}^t$ ,认知权重 $\omega_{2s}^t$ 和社会权重 $\omega_{3s}^t$ ;

**步骤 6** 在网络连通度 $K$ ,链路备选集合 $C_e$ 和种群多样性 $div$ 的约束下,根据式(26)更新粒子的速度 $\mathbf{V}_s^{t+1}$ ,并判断 $\mathbf{V}_s^{t+1}$ 的元素个数 $|\mathbf{V}_s^{t+1}|$ 是否超过速度最大范围 $V_{max}$ ,若超过,则从 $\mathbf{V}_s^{t+1}$ 随机选取 $V_{max}$ 个元素,重新更新 $\mathbf{V}_s^{t+1}$ .并在此基础上,根据式(16)更新粒子的位置 $\mathbf{X}_s^{t+1}$ ;

**步骤 7** 更新粒子的适应度值 $fit(\mathbf{X}_s^{t+1})$ ,自身的局部最佳位置 $\mathbf{P}_s^{t+1}$ 和适应度值 $fit(\mathbf{P}_s^{t+1})$ 以及粒子种群的全局最佳位置 $\mathbf{P}_g^{t+1}$ 和适应度值 $fit(\mathbf{P}_g^{t+1})$ ;

**步骤 8** 判断算法是否满足终止条件,若不满足,则返回步骤4;否则,迭代终止,输出粒子种群的全局最佳粒子。

### 3.4 基于EM-DPSO的多USV网络拓扑优化控制算法复杂度分析(Computational complexity of multi-USV network topology optimization algorithm based on EM-DPSO)

**定理 1** 假设粒子种群规模为 $m$ ,最大迭代次数为 $t_{max}$ ,粒子速度更新的最大范围为 $V_{max}$ ,粒子不是可行解重新更新的最大次数为 $r_{-s,max}$ ,USV的数量为 $n$ .则基于EM-DPSO的多USV网络拓扑优化控制算法的时间复杂度约为

$$O(m, n, t_{max}, V_{max}, r_{-s,max}) \approx O((m^2 + mV_{max} \times r_{-s,max} + mn^3 \times r_{-s,max}) \times t_{max}).$$

下面对定理1进行推导证明。

**证** 根据上述基于EM-DPSO的多USV网络拓扑优化控制的算法流程可知,算法的每次迭代主要包括4部分:①计算粒子种群多样性;②计算粒子更新的权重;③更新粒子的速度、位置;④计算网络连接增益。

首先,计算粒子种群多样性的时间复杂度.粒子种群的多样性通过对粒子的个体多样性进行平均获得,粒子个体多样性的时间复杂度约为 $O(3mn^2) \approx O(mn^2)$ ,对粒子个体多样性进行平均操作的时间复杂度为 $O(m)$ .因此,计算粒子种群多样性的时间复杂度约为 $O(mn^2 + m) \approx O(mn^2)$ ;

其次,计算粒子更新权重的时间复杂度.粒子更新的权重利用粒子的电荷量动态自适应更新,计算粒子电荷量的时间复杂度为 $O(m^2)$ ,在此基础上,计算粒子更新的惯性权重、认知权重和社会权重的时间复杂度均为 $O(m)$ .因此,计算粒子更新权重的时间复杂度约为 $O(m^2 + 3m) \approx O(m^2)$ ;

再次,计算粒子速度、位置更新的时间复杂度.粒子速度更新的时间复杂度与种群多样性阈值和粒子不是可行解重新更新的次数相关,若种群多样性大于阈值,则粒子速度更新包括3部分:惯性部分、认知部分和社会部分;若种群多样性小于阈值,则粒子速度更新包括4部分:惯性部分、认知部分、社会部分和扰动部分.惯性部分的时间复杂度为 $O(mV_{max})$ ,认知部分、社会部分和扰动部分的时间复杂度均为 $O(mn^3)$ .则粒子速度更新的时间复杂度约为 $O((mV_{max} + 3mn^3) \times r_{-s,max}) \approx O((mV_{max} + mn^3) \times r_{-s,max})$ ;粒子位置的更新通过粒子位置与速度的加法操作获得,则粒子位置更新的时间复杂度为 $O(mV_{max} \times r_{-s,max})$ ;因此,更新粒子速度、位置的时间复杂度约为

$$O((mV_{max} + mn^3) \times r_{-s,max} + mV_{max} \times r_{-s,max}) \approx O((mV_{max} + mn^3) \times r_{-s,max});$$

最后,计算网络连接增益的时间复杂度.网络连接增益与网络连接收益和网络连接成本相关,网络连接收益的时间复杂度约为 $O(2mn^3) \approx O(mn^3)$ ,网络连接成本的时间复杂度为 $O(mN^2)$ ,因此,计算网络连接增益的时间复杂度约为 $O(mn^3 + mn^2) \approx O(mn^3)$ .

因此,基于EM-DPSO的多USV网络的拓扑优化控制算法的时间复杂度约为

$$O(m, n, t_{max}, V_{max}, r_{-s,max}) =$$

$$[O(mn^2) + O(m^2) + O((mV_{\max} + mn^3) \times r_{-s_{\max}}) + O(mn^3)] \times t_{\max} \approx O((m^2 + mV_{\max} \times r_{-s_{\max}} + mn^3 \times r_{-s_{\max}}) \times t_{\max}).$$

**注1** 在定理1的假设条件下,与基于DPSO的多USV网络拓扑优化控制算法相比,基于EM-DPSO的多USV网络拓扑优化控制算法的时间复杂度增加了 $O(m^2 \times t_{\max})$ ,算法的时间复杂度并未明显增加.证明如下.

**证** 由文献[12]可知,基于DPSO的多USV网络拓扑优化控制算法的每次迭代主要包括2部分:①更新粒子的速度、位置;②计算网络连接增益.其中,更新粒子速度、位置的时间复杂度约为 $O((mV_{\max} + mn^3) \times r_{-s_{\max}})$ ,计算网络连接增益的时间复杂度约为 $O(mn^3)$ ,因此,基于DPSO的多USV网络拓扑优化控制算法的时间复杂度约为 $O(m, n, t_{\max}, V_{\max}, r_{-s_{\max}}) = [O((mV_{\max} + mn^3) \times r_{-s_{\max}}) + O(mn^3)] \times t_{\max} \approx O((mV_{\max} \times r_{-s_{\max}} + mn^3 \times r_{-s_{\max}}) \times t_{\max})$ .

由定理1可知,基于EM-DPSO的多USV网络拓扑优化控制算法的时间复杂度约为 $O((m^2 + mV_{\max} \times r_{-s_{\max}} + mn^3 \times r_{-s_{\max}}) \times t_{\max})$ ,因此,与基于DPSO的多USV网络拓扑优化控制算法相比,基于EM-DPSO的多USV网络拓扑优化控制算法的时间复杂度增加了 $O(m^2 \times t_{\max})$ ,算法的时间复杂度并未明显增加.

## 4 仿真分析(Simulation analysis)

### 4.1 实验环境与条件假设(Experimental environment and conditions assumptions)

采用Matlab2012a软件,通过与基于DPSO的多USV网络拓扑优化控制算法<sup>[12]</sup>、基于DSPSO的多USV网络拓扑优化控制算法<sup>[19]</sup>进行对比,验证基于EM-DPSO的多USV网络拓扑优化控制算法的有效性.假设条件如下:

1) USV的数量为6,通信频率为300 MHz,收发天线高度为10 m;

2) 多USV网络的网络连通度为2;

3) 6艘USV的位置分别为(0, 0) km, (4, 6) km, (8.5, 8) km, (3, 20) km, (6, 15) km, (2, 10) km;

4) DPSO算法、DSPSO算法和EM-DPSO算法的粒子种群规模都为10,最大迭代次数都为100次,粒子速度更新的最大范围都为5,粒子不是可行解,重新更新的最大次数都为10次;

5) DPSO算法的惯性权重、认知权重、社会权重分别为0.72, 0.26和0.375.

### 4.2 仿真实验与结果分析(Simulation experiment and results analysis)

为了有效清晰地说明本文所提出的算法的有效

性,首先采用Matlab软件,利用精确算法对上述的6艘USV网络拓扑优化控制问题进行确定性求解,获得其最优的网络拓扑结构及其最大的网络连接增益值为0.351056,如图4所示.在此基础上,分别采用基于DPSO的多USV网络拓扑优化控制算法、基于DSPSO的多USV网络拓扑优化控制算法和基于EM-DPSO的多USV网络拓扑优化控制算法对上述问题进行求解,分别独立仿真运行100次,仿真相关结果如表2,表3,图5和图6所示.




图4 6艘USV网络的最优拓扑结构

Fig. 4 The optimal topology of six USV network

表2是3种算法获得的最优解的结果对比表.利用平均相对偏差作为算法性能的评价指标.由表2可知,在100次的独立仿真实验中,3种算法均可以获得最优解,但基于DPSO的多USV网络拓扑优化控制算法取得最优解的次数是92次,最优解适应度值的平均值为0.350801,平均相对偏差为 $7.273e-4$ ;基于DSPSO的多USV网络拓扑优化控制算法取得最优解的次数是95次,最优解适应度值的平均值为0.350946,平均相对偏差为 $3.126e-4$ ;而基于EM-DPSO的网络拓扑优化控制算法取得最优解的次数是99次,最优解适应度值的平均值为0.350954,平均相对偏差为 $2.896e-4$ ,算法性能得到了提升.

表3是3种算法的收敛速度对比表.由表3可知,基于DPSO的多USV网络拓扑优化控制算法取得最优解的平均迭代次数是35.46,算法的搜索效率是35.46%;基于DSPSO的多USV网络拓扑优化控制算法取得最优解的平均迭代次数是32.46,算法的搜索效率是32.46%;基于EM-DPSO的多USV网络拓扑优化控制算法取得最优解的平均迭代次数是21.32,算法的搜索效率是21.32%,其收敛速度和搜索效率得到了显著提升.

图5是3种算法分别运行100次,最优解适应度值的平均值随迭代次数变化的收敛曲线.由图5可知,



基于EM-DPSO的多USV网络拓扑优化控制算法的收敛速度最快, 基于DSPSO的多USV网络拓扑优化控制算法的收敛速度次之, 基于DPSO的多USV网络拓扑优化控制算法的收敛速度最慢。

表 2 3种算法取得的最优解的结果对比表  
Table 2 The optimal results of three algorithms

算法	仿真次数	取得最优解的次数	理论最优解的适应度值	最优解适应度值的最大值	最优解适应度值的最小值	最优解适应度值的平均值	平均相对偏差
DPSO	100	92	0.351056	0.351056	0.340888	0.350801	7.273e-4
DSPSO	100	95	0.351056	0.351056	0.348861	0.350946	3.126e-4
EM-DPSO	100	99	0.351056	0.351056	0.340888	0.350954	2.896e-4

平均相对偏差=(理论最优解-最优解的平均值)/理论最优解

表 3 3种算法的收敛速度对比表  
Table 3 The convergence rate of three algorithms

算法	迭代次数	取得最优解的平均迭代次数	搜索效率
DPSO	100	35.46	35.46%
DSPSO	100	32.46	32.46%
EM-DPSO	100	21.32	21.32%

搜索效率=取得最优解的平均迭代次数/总迭代次数

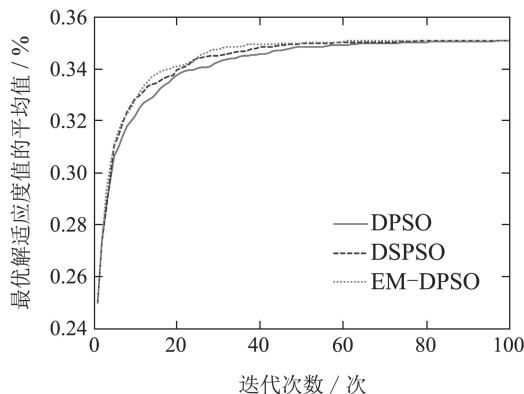


图 5 最优解适应度值的平均值变化曲线  
Fig. 5 The curves of optimal fitness value

图6是3种算法分别运行100次, 粒子种群多样性的平均值随迭代次数变化的收敛曲线。由图6可知, 基于DPSO的多USV网络拓扑优化控制算法的粒子种群多样性最优, 基于DSPSO的多USV网络拓扑优化控制算法的粒子种群多样性次之, 而基于EM-DPSO的多USV网络拓扑优化控制算法的粒子种群多样性最差。这是由于基于DPSO的多USV网络拓扑优化控制算法的收敛速度最慢, 基于DSPSO的多USV网络拓扑优化控制算法的收敛速度次之, 基于EM-DPSO的多USV网络拓扑优化控制算法的收敛速度最快。

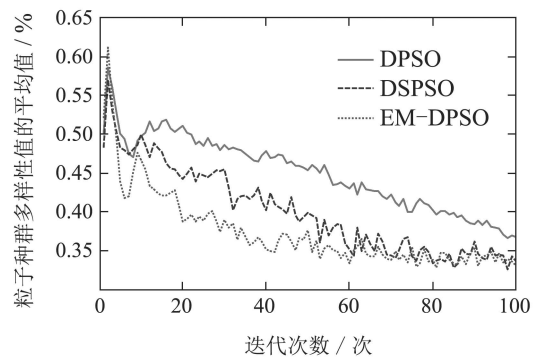


图 6 粒子种群多样性变化曲线  
Fig. 6 The curves of particle swarm diversity

此外, 随着迭代次数的增加, 基于DPSO的多USV网络拓扑优化控制算法的粒子种群多样性一直逐渐下降, 这可能会导致在算法迭代寻优的后期无法保证粒子种群的多样性。基于DSPSO的多USV网络拓扑优化控制算法和基于EM-DPSO的多USV网络拓扑优化控制算法的粒子种群多样性都先下降, 然后趋于平稳。这是由于这两种算法在迭代过程中, 都引入了适当的机制确保粒子种群的多样性。与基于EM-DPSO的多USV网络拓扑优化控制算法相比, 基于DSPSO的多USV网络拓扑优化控制算法借助阶梯突变机制完成惯性权重的动态调整, 以确保粒子种群的多样性。但该机制可能需要对惯性权重进行多次调整以克服算法的早熟收敛, 从而导致算法复杂度的增加。

由以上仿真结果分析可知, 基于EM-DPSO的多USV网络拓扑优化控制算法具有以下特点: ① 能够根据粒子的电荷量动态自适应调整控制参数, 提高算法的收敛速度和自适应能力; ② 能够克服算法的早熟收敛, 在算法的迭代过程中, 引入排斥机制引导粒子向未搜索区域移动, 提高算法的全局搜索能力。

## 5 结论(Conclusions)

本文提出了一种基于EM-DPSO的多USV网络拓扑优化控制算法. 该算法在链路通信质量和网络连通度的约束下, 综合考虑网络连接收益和网络连接成本构建多USV网络拓扑优化控制模型. 在EM-DPSO算法的迭代寻优过程中, 通过模拟电磁场中带电粒子间的相互作用, 动态自适应调整控制参数, 吸引粒子向最优搜索区域快速移动, 加快模型的收敛速度; 同时, 引入排斥机制, 引导粒子向未搜索区域移动, 克服算法的早熟收敛, 确保获得模型的全局最优解. 仿真结果对比证明了该算法能够获得模型的全局最优解, 确保粒子种群的多样性, 加快模型的收敛速度.

## 参考文献(References):

- [1] ŠVEC P, THAKUR A, RABOIN E, et al. Target following with motion prediction for unmanned surface vehicle operating in cluttered environments [J]. *Autonomous Robots*, 2014, 36(4): 383 – 405.
- [2] AI-ANI A D, SEITZ J. QoS-aware routing in multi-rate ad hoc networks based on ant colony optimization [J]. *Network Protocols and Algorithms*, 2016, 7(4): 1 – 25.
- [3] DUAN D L, LING X D, WU X Y, et al. Reconfiguration of distribution network for loss reduction and reliability improvement based on an enhanced genetic algorithm [J]. *International Journal of Electrical Power & Energy Systems*, 2015, 64(1): 88 – 95.
- [4] SAKAMOTO S, ODA T, KULLA E, et al. Performance analysis of WMNs using simulated annealing algorithm for different temperature values [C] // *Proceedings of the 7th International Conference on Complex, Intelligent, and Software Intensive Systems (CISIS)*. Taizhong: IEEE, 2013: 164 – 168.
- [5] KULKARNI R V, VENAYAGAMOORTHY G K. Particle swarm optimization in wireless-sensor networks: A brief survey [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2011, 41(2): 262 – 267.
- [6] HO D, GRÖTLI E I, SUJIT P B, et al. On topology selection and UAV path planning in wireless sensor networks [C] // *Proceedings of the 2013 International Conference on Unmanned Aircraft Systems (ICUAS)*. Atlanta: IEEE, 2013: 59 – 68.
- [7] FANG Wei, SUN Jun, XIE Zhenping, et al. Convergence analysis of quantum-behaved particle swarm optimization algorithm and study on its control parameter [J]. *Acta Physica Sinica*, 2010, 59(6): 3686 – 3694.  
(方伟, 孙俊, 谢振平, 等. 量子粒子群优化算法的收敛性分析及控制参数研究 [J]. 物理学报, 2010, 59(6): 3686 – 3694.)
- [8] KEERTHIPRIYA N, LATHA R S. Adaptive cluster formation in MANET using particle swarm optimization [C] // *Proceedings of the 3rd International Conference on Signal Processing, Communication and Networking (ICSCN)*. Chennai: IEEE, 2015: 1 – 7.
- [9] DENGIZ O, KONAK A, SMITH A E. Connectivity management in mobile ad hoc networks using particle swarm optimization [J]. *Ad Hoc Networks*, 2011, 9(7): 1312 – 1326.
- [10] SINGH B, LOBIYAL D K. A novel energy-aware cluster head selection based on particle swarm optimization for wireless sensor networks [J]. *Human-Centric Computing and Information Sciences*, 2012, 2(1): 13 – 30.
- [11] GONG M G, CAI Q, CHEN X W, et al. Complex network clustering by multiobjective discrete particle swarm optimization based on decomposition [J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(1): 82 – 97.
- [12] KHAN S A, ENGELBRECHT A P. A fuzzy particle swarm optimization algorithm for computer communication network topology design [J]. *Applied Intelligence*, 2012, 36(1): 161 – 177.
- [13] HAO Xiaochen, DOU Jingjing, LIU Bin. Path-Loss based distributed topology control algorithm for wireless sensor networks [J]. *Journal of Software*, 2009, 20(12): 3213 – 3222.  
(郝晓辰, 窦晶晶, 刘彬. 基于路径损耗的无线传感器网络分布式拓扑控制算法 [J]. 软件学报, 2009, 20(12): 3213 – 3222.)
- [14] HUANG F, BAI Y, DU W C. Maritime radio propagation with the effects of ship motions [J]. *Journal of Communication*, 2015, 10(5): 345 – 351.
- [15] ZHANG Jing, WANG Wanliang, XU Xinli, et al. Hybrid particle-swarm optimization for multi-objective flexible job-shop scheduling problem [J]. *Control Theory & Applications*, 2012, 29(6): 715 – 722.  
(张静, 王万良, 徐新黎, 等. 混合粒子群算法求解多目标柔性作业车间调度问题 [J]. 控制理论与应用, 2012, 29(6): 715 – 722.)
- [16] ZHANG Changsheng, SUN Jigui, OUYANG Dantong. A self-adaptive discrete particle swarm optimization algorithm [J]. *Acta Electronica Sinica*, 2009, 37(2): 299 – 304.  
(张长胜, 孙吉贵, 欧阳丹彤. 一种自适应离散粒子群算法及其应用研究 [J]. 电子学报, 2009, 37(2): 299 – 304.)
- [17] OLASCUAGA-CABRERA J G, LÓPEZ-MELLADO E, MENDEZ-VAZQUEZ A. A multi-objective PSO strategy for energy-efficient ad-hoc networking [C] // *Proceedings of the 2011 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. Alaska: IEEE, 2011: 2632 – 2639.
- [18] WANG Qiang, ZHANG An, SONG Zhijiao. Simulation study on improved discrete particle swarm optimization algorithm for multiple UAV cooperation task assignment [J]. *Journal of System Simulation*, 2014, 26(5): 1149 – 1155.  
(王强, 张安, 宋志蛟. UAV 协同任务分配的改进DPSO算法仿真研究 [J]. 系统仿真学报, 2014, 26(5): 1149 – 1155.)
- [19] GUO Sen, QIN Guihe, ZHANG Jindong, et al. A novel particle swarm optimization for multi-objective vehicle routing problem [J]. *Journal of Xi'an Jiaotong University*, 2016, 50(9): 97 – 104.  
(郭森, 秦贵和, 张晋东, 等. 多目标车辆路径问题的粒子群优化算法研究 [J]. 西安交通大学学报, 2016, 50(9): 97 – 104.)

## 附录 EM-DPSO算法收敛性分析(Convergence analysis of EM-DPSO)

参考文献[7], 利用随机算法理论对EM-DPSO算法的全局收敛性进行证明. 首先给出一些证明所要用的假设和定理.

**定义 1** 给定一个目标函数 $f$ , 它的解空间是从 $\mathbb{R}^n$ 到 $\mathbb{R}$ ,  $\mathbf{A}$ 是 $\mathbb{R}^n$ 的一个子集. 在 $\mathbf{A}$ 中寻找一个点 $z$ , 它能够使得函数 $f$ 的值最小化或者至少能够生成一个函数 $f$ 在 $\mathbf{A}$ 上的下确界 $\psi$ , 其中 $\psi = \inf\{m : v[z \in \mathbf{A} | f(z) < m] > 0\}$ ,  $v[\mathbf{B}]$ 是在集合 $\mathbf{B}$ 上的Lebesgue测度.

**假设 1**  $f(H(z, \xi)) \leq f(z)$ , 如果 $\xi \in \mathbf{A}$ , 则 $f(H(z, \xi)) \leq f(\xi)$ .

**注 2** 假设1中的 $H$ 是指可以在待求解问题的空间产生一个解的函数, 应能够保证 $H$ 所产生的新个体优于当前个体.

**假设 2** 对于 $\mathbf{A}$ 的Borel子集 $\mathbf{B}$ , 若其测度 $v[\mathbf{B}] > 0$ , 则 $\prod_{t=1}^{+\infty} (1 - \mu_t[\mathbf{B}]) = 0$ ,  $\mu_t[\mathbf{B}]$ 是由测度 $\mu_t$ 所得到 $\mathbf{B}$ 的概率.

**定理 2** (全局收敛的充要条件) 假设目标函数 $f$ 为可测函数, 区域 $\mathbf{A}$ 是 $\mathbb{R}^n$ 的可测子集, 能够满足假设1和假设2,

设  $\{z_t\}_{t=1}^{+\infty}$  为算法生成的解序列, 可得  $\lim_{t \rightarrow +\infty} P[z_t \in R_\epsilon] = 1$ ,  $P[z_t \in R_\epsilon]$  是指在第  $t$  次迭代由算法生成的解  $z_t \in R_\epsilon$  的概率,  $R_\epsilon$  为全局最优点集合.

下面利用定理 2 对 EM-DPSO 算法的全局收敛性进行证明, 也就是证明 EM-DPSO 算法同时满足假设 1 和假设 2.

首先证明 EM-DPSO 算法满足假设 1. 根据 EM-DPSO 算法的原理和推导过程, 可以将 EM-DPSO 算法的函数  $H$  定义为

$$H(\mathbf{P}_g^t, \mathbf{X}_s^t) = \begin{cases} \mathbf{P}_g^t, & f(\mathbf{P}_g^t) \geq f(F_{\text{app}}(\mathbf{X}_s^t)), \\ F_{\text{app}}(\mathbf{X}_s^t), & f(\mathbf{P}_g^t) < f(F_{\text{app}}(\mathbf{X}_s^t)). \end{cases}$$

式中:  $F_{\text{app}}(\mathbf{X}_s^t)$  表示 EM-DPSO 算法的搜索操作, 即  $\mathbf{X}_s^{t+1} = F_{\text{app}}(\mathbf{X}_s^t)$ ;  $\mathbf{P}_g^t$  表示粒子种群从开始到第  $t$  次迭代所取得的全局最佳粒子. 显然函数  $H$  保证所产生的新个体优于当前个体. 即, EM-DPSO 算法满足假设 1.

进而证明 EM-DPSO 算法满足假设 2. 为了满足假设 2, 规模为  $m$  的粒子种群的样本空间的并必须包含  $\mathbf{A}$ , 即  $\mathbf{A} \subseteq \bigcup_{s=1}^m \mathbf{M}_s^t$ ,  $\mathbf{M}_s^t$  表示算法在第  $t$  次迭代粒子  $s$  的支撑集. 令  $\mathbf{U}^t$  表示算法在第  $t$  次迭代搜索到的结果, 在更新全局最优位

置中, 保证了当  $f(\mathbf{P}_g^t) < f(\mathbf{U}^t)$ , 存在一个粒子  $s_0$ , 其支撑集  $\mathbf{M}_{s_0}^t = \mathbf{A}$ ; 所以  $\mathbf{A} \subseteq \bigcup_{s=1}^m \mathbf{M}_s^t$ . 定义  $\mathbf{A}$  的 Borel 子集  $\mathbf{B} = \mathbf{M}_s^t$ , 则有  $v[\mathbf{B}] > 0$ ,  $\mu_t[\mathbf{B}] = \sum_{s=1}^m \mu_s^t[\mathbf{B}] = 1$ , 从而  $\prod_{t=1}^{+\infty} (1 - \mu_t[\mathbf{B}]) = 0$ . 即, EM-DPSO 算法满足假设 2.

假设  $\{\mathbf{P}_g^t\}_{t=1}^{+\infty}$  为 EM-DPSO 算法的解序列,  $\mathbf{P}_g^t$  为粒子种群的全局最佳粒子, 由于 EM-DPSO 算法同时满足假设 1 和假设 2, 因此, EM-DPSO 算法以概率 1 全局收敛.

#### 作者简介:

**崔亚妮** (1990-), 女, 博士研究生, 目前研究方向为多智能体自主协同控制与决策, E-mail: cyn0213@163.com;

**任佳** (1981-), 男, 博士, 副教授, 博士生导师, 目前研究方向为人工智能、机器学习, E-mail: renjia@hainu.edu.cn;

**杜文才** (1953-), 男, 博士, 教授, 博士生导师, 目前研究方向为计算机网络、海洋通信, E-mail: wencai@hainu.edu.cn;

**SHIKHIN Vladimir** (1953-), 男, 博士, 教授, 博士生导师, 目前研究方向为智能体控制, E-mail: ShikhinVA@mpei.ru.