先进布局无人机多目标自适应概率引导控制分配

郑峰婴[1†], 王 峰[1], 甄子洋[2], 许梦园[1], 范 涛[1]

(1. 南京航空航天大学 航天学院, 江苏 南京 211106; 2. 南京航空航天大学 自动化学院, 江苏 南京 211106)

摘要: 针对先进布局无人机多操纵面冗余的控制分配问题, 提出一种基于自适应概率引导的混合多目标控制分配方法. 首先, 根据冗余舵面操纵特性, 建立带约束的舵面动态效能模型, 提出精度需求不同的混合多目标优化指标. 随后, 为了综合平衡各目标寻优精度与求解速度提出基于自适应概率引导的多目标粒子群控制分配方法. 该方法根据各目标最优值与期望精度差值构建自适应概率函数, 依概率选择全局最优解, 引导种群向各目标期望精度方向精细搜索以提升算法解算精度, 减少无用搜索以提高求解速度; 同时, 根据收敛性指标增加变异因子, 避免算法陷入局部最优. 最后, 仿真验证该方法可有效处理舵面耦合及非线性特性, 减少能耗损失, 实现操纵面多目标控制分配, 使得无人机快速平稳跟踪控制指令.

关键词: 先进布局; 自适应概率引导; 多目标粒子群算法; 控制分配; 飞行控制

引用格式: 郑峰婴, 王峰, 甄子洋, 等. 先进布局无人机多目标自适应概率引导控制分配. 控制理论与应用, 2022, 39(12): 2366 – 2376

DOI: 10.7641/CTA.2021.10625

Control allocation of multi-objective adaptive probabilistic guidance for advanced layout unmanned aerial vehicle

ZHENG Feng-ying[1†], WANG Feng[1], ZHENG Zi-yang[2], XU Meng-yuan[1], FAN Tao[1]

(1. School of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 211106, China;
2. School of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 211106, China)

Abstract: A hybrid multi-objective control allocation method based on the adaptive probability guidance is proposed to solve the problem of redundant control allocation of advanced layout unmanned aerial vehicle (UAV). Firstly, according to the control characteristics of redundant control surfaces, a constrained dynamic effectiveness model of control surfaces is established, and the hybrid multi-objective optimization indexes with different precision requirements are proposed. Then, in order to comprehensively balance the optimization precision and solution speed of each target, a multi-objective particle swarm control allocation method based on the adaptive probability guidance is proposed. The method constructs an adaptive probability function according to the difference between the optimal value and the expected precision of each target, selects the global optimal solution according to probability, guides the population to search finely in the direction of the expected precision of each target, improves the solution precision of the algorithm, and reduces useless search to improve the solution speed. At the same time, according to the convergence index, the variation factor is added to avoid the algorithm falling into local optimum. Finally, the simulation results show that the method can effectively deal with the coupling and nonlinear characteristics of the control surface, reduce the energy loss, and realize the multi-objective control allocation of the control surface, so that the UAV can track the control command quickly and smoothly.

Key words: advanced layout; adaptive probability guidance; multi-objective particle swarm optimization algorithm (MOPSO); control allocation; flight control

Citation: ZHENG Fengying, WANG Feng, ZHENG Ziyang, et al. Control allocation of multi-objective adaptive probabilistic guidance for advanced layout unmanned aerial vehicle. *Control Theory & Applications*, 2022, 39(12): 2366 – 2376

收稿日期: 2021−07−14; 录用日期: 2021−12−01.

[†]通信作者. E-mail: zhfy@nuaa.edu.cn; Tel.: +86 13913960006.

本文责任编委: 胡德文.

国家自然科学基金项目(61803200, 61973158), 装备预研重点实验室基金项目(6142220180304)资助.

Supported by the National Natural Science Foundation of China (61803200, 61973158) and the Equipment Pre-Research Key Laboratory Fund (6142220180304).

1　引言

现代无人机通常会采用先进的气动布局方式, 以达到更优越的性能需求. 如飞翼布局无人机拥有良好的隐身能力、较好气动效率以及高的升阻比, 逐渐成为高性能无人机的首选气动布局方式. 但此布局方式也同时给无人机的控制分配策略的设计带来挑战[1−2]. 首先, 舵面冗余配置, 布置紧密, 舵面之间气动交互作用增强, 交叉耦合效应凸显; 其次, 舵面偏转与控制力矩间呈现强非线性关系, 且各舵面偏转角及偏转速率受范围约束; 最后, 在控制分配时通常存在多个性能目标需要优化[3−4]. 由此如何解决舵面强耦合、非线性、控制标量约束以及多目标同时优化是研究先进布局无人机的控制分配方法时面临的难题.

目前多操纵面无人机控制律及控制分配方法的研究引起了国内外学者的广泛关注[5−8]. 文献[9]研究了输入有约束的飞翼布局无人机姿态控制问题, 提出一种采用扩张状态观测器的反步滑模控制方法结合基于线性不等式的控制分配方法实现了无人机的抗扰动控制; 文献[10]采用鲁棒最优控制结合强化学习的方法实现了多操纵面无人机的在线控制分配; 文献[11]提出一种基于迎角反馈的有偏差动控制方法, 控制分配采取基于可达集的直接分配法, 实现对XQ-6B型多操纵面无人机的控制; 文献[12]采用增量动态逆控制方法结合权重分配法实现飞翼布局无人机容错控制. 然而上述研究在控制分配方法上大都基于线性舵面操纵效率模型, 忽略了舵面之间交叉耦合非线性及偏转非线性特性, 且分配优化目标单一或未区分多目标的重要度.

以非线性舵效模型为基础的多操纵面控制分配通常可以视为非线性多目标优化问题. 多目标粒子群算法作为一种智能优化算法具有自组织、并行高效、通用性强和调节参数少, 易于工程实现等优点, 已被广泛应用于求解非线性多目标优化问题[13]. 目前, 根据进化机制不同多目标粒子群算法可分为以下3类: 1) 基于分解的多目标粒子群算法[14−15], 是将多目标问题分解为一系列单目标问题进行求解; 2) 基于指标的多目标粒子群算法[16−17], 是通过使用性能评价指标来引导搜索过程及对解的选择过程; 3) 基于支配关系的多目标粒子群算法[18−19], 基本思想是基于Pareto支配关系从种群中筛选出非支配解. 然而, 与一般多目标优化问题需获得均匀分布于整个Pareto前沿上的最优解集不同, 非线性控制分配只需求解出满足分配精度需求的一组可行解, 因此采用常规多目标粒子群算法会存在求解效率过低的问题. 但通过将精度需求的偏好信息融入算法, 可使算法集中搜索偏好区域, 从而能有效利用计算资源、提升求解效率. 在偏好信息的融入方式上, 学者们从偏好集、占优关系、权重向量及角度关系[20]等方面做出了研究和改进. 此类改进虽提升了算法的求解效率, 但对于精度需求差异较大的多目标控制分配问题, 难以保证高精度需求目标的优化效果. 为此需要根据问题特点, 针对各目标的精度需求改进算法, 以提升求解精度使其满足控制分配目标要求.

本文针对一类飞翼式先进布局无人机多操纵面控制分配问题, 提出一种基于自适应概率引导多目标粒子群控制分配方法. 在综合考虑舵面非线性特性及控制约束的基础上, 建立舵面操纵非线性动态效能模型, 根据飞行任务实际需求提出不同精度的混合多目标性能指标. 通过计算种群当前各目标最优值与期望精度间差值, 构建概率函数, 由概率函数自适应改变全局最优解的筛选方式, 迅速引导种群在精度偏重目标方向精细搜索, 以提高重要目标寻优精度与求解速度; 同时, 通过收敛性指标评估种群进化状态, 对于进化陷入停滞的种群增加变异因子, 有效改善算法易陷入局部最优特性.

2　先进布局无人机的控制分配问题

2.1　舵面操纵非线性动态效能模型

本文研究对象如图1所示, 该型布局无人机采用翼身融合的设计方式, 取消垂尾, 舵面由3组升降副翼和1组阻力方向舵组成, 对称分布于无人机尾部.

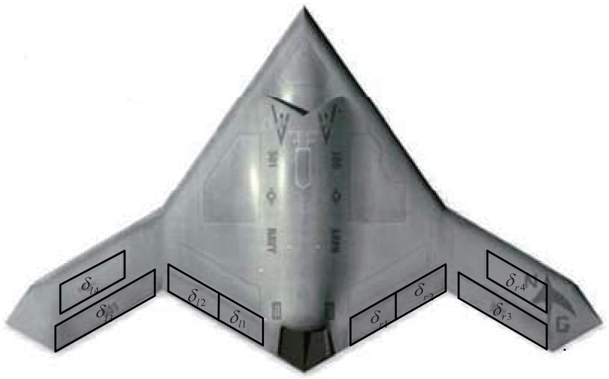

图 1　飞翼式先进布局无人机

Fig. 1　Flying wing advanced layout UAV

图中δ_{l1}, δ_{l2}, δ_{l3}和δ_{r1}, δ_{r2}, δ_{r3}为升降副翼, 可独立偏转, 偏转范围为$-20° \sim 20°$, 生成滚转和俯仰控制力矩, 并带来偏航耦合力矩; δ_{l4}和δ_{r4}为阻力方向舵, 偏转范围为$0° \sim 90°$, 生成偏航控制力矩, 带来滚转俯仰耦合控制力矩.

通常情况下, 为利于控制律的设计与舵面的控制分配, 期望舵面的偏转与控制力矩之间呈线性关系, 但实际上飞翼布局无人机由于其独特的布局会存在较强的非线性特性. 对此, 分析如下:

1) 舵面偏转非线性.

飞翼式先进布局无人机由于升降副翼正负偏转均会产生负控制力矩系数, 偏航通道偏转非线性强, 呈现类二次函数式的非线性特性. 采用多项式函数对舵

面偏转非线性进行拟合. 多项式的阶数越高对非线性的体现越好, 但同时高阶多项式会增加控制分配算法计算负担. 由于三阶多项式已能较好体现舵效非线性, 因此选择三阶多项式函数对舵面非线性特性进行拟合, 即

$$C_n(\delta_i) = p_1\delta_i^3 + p_2\delta_i^2 + p_3\delta_i + p_4, \tag{1}$$

式中: $C_n(\delta_i)$为对应舵面的偏航力矩系数; δ_{li}为各升降副翼偏转角度.

以左侧舵面为例, 各通道控制力矩系数与舵面偏转之间关系如图2所示. 俯仰与滚转通道非线性体现在阻力方向舵在70°偏角附近出现较小的斜率变化, 整体线性度较好; 而在偏航通道方面, 升降副翼在0偏位置附近呈现强非线性关系.

2) 舵面耦合非线性.

飞翼式先进布局无人机的舵面布置较为紧密, 舵面之间会产生交叉耦合效应, 即某一舵面偏转会对其他舵面的操纵效率产生影响. 主要体现在阻力方向舵与邻近的升降副翼上. 以左侧舵面为例, 在考虑舵面之间耦合情况下将耦合舵面的控制力矩系数可表示如下:

$$\begin{cases} C_l(\delta_{l3},\delta_{l4}) = C_l(\delta_{l3}) + C_l(\delta_{l4}) + \Delta C_l(\delta_{l3},\delta_{l4}), \\ C_m(\delta_{l3},\delta_{l4}) = \\ C_m(\delta_{l3}) + C_m(\delta_{l4}) + \Delta C_m(\delta_{l3},\delta_{l4}), \\ C_n(\delta_{l3},\delta_{l4}) = C_n(\delta_{l3}) + C_n(\delta_{l4}) + \Delta C_n(\delta_{l3},\delta_{l4}), \end{cases} \tag{2}$$

其中: $C_l(\delta_{l3},\delta_{l4})$, $C_m(\delta_{l3},\delta_{l4})$, $C_n(\delta_{l3},\delta_{l4})$为两耦合舵面分别在三通道产生的控制力矩数; $C_l(\delta_{l3})$, $C_l(\delta_{l4})$, $C_m(\delta_{l3})$, $C_m(\delta_{l4})$, $C_n(\delta_{l3})$, $C_n(\delta_{l4})$为δ_{l3}和δ_{l4}两舵面单独偏转在三通道产生控制力矩系数; $\Delta C_l(\delta_{l3},\delta_{l4})$, $\Delta C_m(\delta_{l3},\delta_{l4})$和$\Delta C_n(\delta_{l3}\delta_{l4})$为$\delta_{l3}$和$\delta_{l4}$两舵面交叉耦合产生控制力矩增量系数.

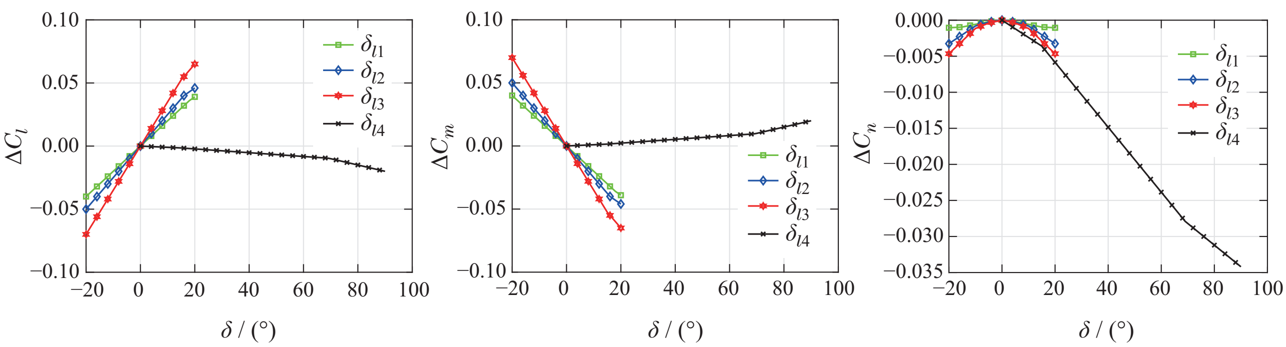

(a) ΔC_l (b) ΔC_m (c) ΔC_n

图 2 各通道控制力矩系数与舵面偏转之间关系

Fig. 2 Relationship between control moment coefficient of each channel and rudder deflection

交叉耦合产生控制力矩增量系数可表示为双线性形式, 即

$$\begin{cases} \Delta C_l(\delta_3,\delta_4) = \dfrac{\partial^2 C_l}{\partial\delta_3\partial\delta_4}\delta_3\delta_4, \\ \Delta C_m(\delta_3,\delta_4) = \dfrac{\partial^2 C_m}{\partial\delta_3\partial\delta_4}\delta_3\delta_4, \\ \Delta C_n(\delta_3,\delta_4) = \dfrac{\partial^2 C_n}{\partial\delta_3\partial\delta_4}\delta_3\delta_4. \end{cases} \tag{3}$$

$$C_n(\delta_i) = p_1\delta_i^3 + p_2\delta_i^2 + p_3\delta_i + p_4, \tag{4}$$

式中: $C_n(\delta_i)$为对应舵面的偏航力矩系数; δ_{li}为各升降副翼偏转角度.

以左侧舵面为例, 在阻力方向舵偏转情况下, 邻近升降副翼偏转所产生的交叉耦合效应如图3所示. 耦合效应主要体现在, 当阻力方向舵偏角较大时会极大影响相邻升降副翼所产生的滚转与俯仰控制力矩. 图3中耦合改变比例为交叉耦合力矩增量系数与两舵面单独偏转产生控制力矩系数和的比值.

由此, 得到舵面操纵非线性动态效能模型

$$\begin{cases} C_{l\delta} = C_{l\delta_{l1}}\delta_{l1} + C_{l\delta_{l2}}\delta_{l2} + C_{l\delta_{l3}}\delta_{l3} + C_{l\delta_{l4}}\delta_{l4} + \\ \quad C_{l\delta_{r1}}\delta_{r1} + C_{l\delta_{r2}}\delta_{r2} + C_{l\delta_{r3}}\delta_{r3} + C_{l\delta_{r4}}\delta_{r4} + \\ \quad \dfrac{\partial^2 C_l}{\partial\delta_{l3}\partial\delta_{l4}}\delta_{l3}\delta_{l4} + \dfrac{\partial^2 C_l}{\partial\delta_{r3}\partial\delta_{r4}}\delta_{r3}\delta_{r4}, \\ C_{m\delta} = C_{m\delta_{l1}}\delta_{l1} + C_{m\delta_{l2}}\delta_{l2} + C_{m\delta_{l3}}\delta_{l3} + \\ \quad C_{m\delta_{l4}}\delta_{l4} + C_{m\delta_{r1}}\delta_{r1} + C_{m\delta_{r2}}\delta_{r2} + \\ \quad C_{m\delta_{r3}}\delta_{r3} + C_{m\delta_{r4}}\delta_{r4} + \\ \quad \dfrac{\partial^2 C_m}{\partial\delta_{l3}\partial\delta_{l4}}\delta_{l3}\delta_{l4} + \dfrac{\partial^2 C_m}{\partial\delta_{r3}\partial\delta_{r4}}\delta_{r3}\delta_{r4}, \\ C_{n\delta} = C_n(\delta_{l1}) + C_n(\delta_{l2}) + C_n(\delta_{l3}) + C_n(\delta_{l4}) + \\ \quad C_n(\delta_{r1}) + C_n(\delta_{r2}) + C_n(\delta_{r3}) + C_n(\delta_{r4}) + \\ \quad \dfrac{\partial^2 C_n}{\partial\delta_{l3}\partial\delta_{l4}}\delta_{l3}\delta_{l4} + \dfrac{\partial^2 C_n}{\partial\delta_{r3}\partial\delta_{r4}}\delta_{r3}\delta_{r4}. \end{cases} \tag{5}$$

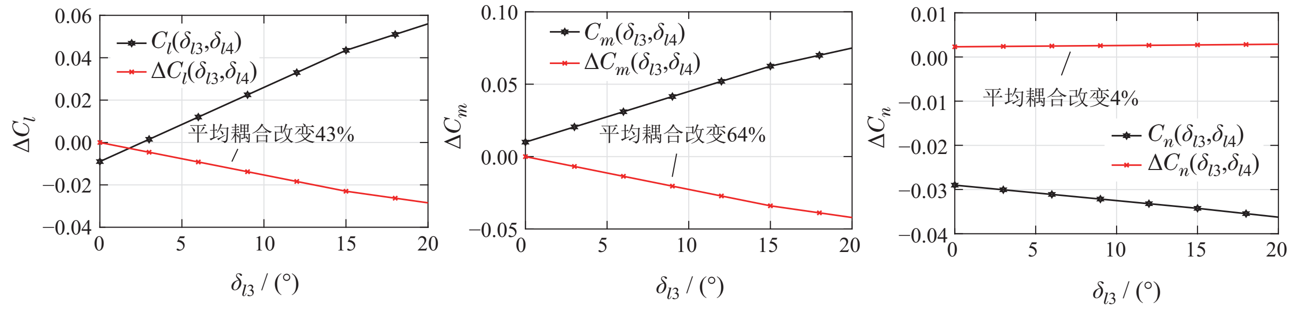

(a) ΔC_l (b) ΔC_m (c) ΔC_n

图 3 阻力方向舵与升降副翼间交叉耦合效应

Fig. 3 Cross-coupling effect between drag rudder and lift aileron

2.2 控制分配策略设计

控制系统根据飞行控制律计算并输出滚转、俯仰和偏航三通道控制力矩系数(滚转控制力矩系数$C_{l\delta}$、俯仰控制力矩系数$C_{m\delta}$、偏航控制力矩系数$C_{n\delta}$)令三通道控制力矩系数为虚拟控制指令$\boldsymbol{v}$, 即

$$\boldsymbol{v}=\begin{bmatrix}C_{l\delta}\\C_{m\delta}\\C_{n\delta}\end{bmatrix},$$

则无人机的控制分配问题可描述为: 给定虚拟控制指令$\boldsymbol{v}$, 寻找可行的舵面偏转指令$\boldsymbol{\delta}$满足上式. 若存在多组解, 则需要选择某种意义的优化指标下的最优解; 若无解, 则需要寻找跟踪虚拟指令精度最高的一组解. 在实际系统中, 舵面受载荷、结构等物理约束, 使得舵面偏转范围以及偏转速率受到限制. 即对于舵面需要满足以下约束.

由此, 根据多优化目标并考虑无人机操纵量边界约束条件、操纵变量变化速率约束条件和模型非线性化约束条件设计无人机多目标控制分配策略, 可表述为

$$\begin{aligned}&\min\ \varGamma=(f_1(\boldsymbol{\delta},\boldsymbol{v}),f_2(\boldsymbol{\delta},\boldsymbol{v}),\cdots,f_n(\boldsymbol{\delta},\boldsymbol{v})),\\&\text{s.t.}\begin{cases}\boldsymbol{v}(t)=C(\boldsymbol{\delta}),\\\boldsymbol{\delta}_{\min}(t)\leqslant\boldsymbol{\delta}(t)\leqslant\boldsymbol{\delta}_{\max}(t),\\\dot{\boldsymbol{\delta}}_{\min}(t)\leqslant\dot{\boldsymbol{\delta}}(t)\leqslant\dot{\boldsymbol{\delta}}_{\max}(t),\end{cases}\end{aligned}\tag{6}$$

式中: n为无人机控制分配性能指标的个数; f_i为性能指标函数; $\boldsymbol{\delta}=[\delta_{l1}\ \ \delta_{l2}\ \ \delta_{l3}\ \ \delta_{l4}\ \ \delta_{r1}\ \ \delta_{r2}\ \ \delta_{r3}\ \ \delta_{r4}]$为控制分配输出的8个舵面操纵变量; $\dot{\boldsymbol{\delta}}$为8个操纵变量变化速率.

根据各优化目标的重要度给出不同的寻优目标精度, 为保证寻优结果满足各目标精度要求, 同时加快搜索速度, 本文提出自适应概率引导多目标粒子群算法, 实时在线寻优, 实现多操纵面飞翼式先进布局无人机飞行过程控制分配, 保证无人机快速准确跟踪控制指令, 同时提高控制面操纵效率, 减少舵面耗能. 具体控制策略如图4所示.

3 自适应概率引导多目标粒子群算法

定义 1 Pareto支配: 对于满足式(6)约束条件的$\boldsymbol{x}=[\boldsymbol{\delta}_x,\boldsymbol{v}_x]$与$\boldsymbol{s}=[\boldsymbol{\delta}_s,\boldsymbol{v}_s]$, 若对于$\forall i\in(1,2,\cdots,n)$均有$f_i(\boldsymbol{s})\leqslant f_i(\boldsymbol{x})$, 且$\exists i\in(1,2,\cdots,n)$使得$f_i(\boldsymbol{s})<f_i(\boldsymbol{x})$, 则称$\boldsymbol{s}$支配$\boldsymbol{x}$, 记做$\boldsymbol{s}\prec\boldsymbol{x}$.

定义 2 Pareto最优解: 针对式(6)多目标优化问题, 若$\exists\boldsymbol{x}^*=[\boldsymbol{\delta}^*,\boldsymbol{v}^*]$满足约束条件, 使得任意满足约束的$\boldsymbol{x}=[\boldsymbol{\delta},\boldsymbol{v}]$均有$f_i(\boldsymbol{x}^*)\leqslant f_i(\boldsymbol{x})$, $(i=1,2,\cdots,n)$, 且$\exists f_i(\boldsymbol{x}^*)<f_i(\boldsymbol{x})$, 则$\boldsymbol{x}^*$为式(6) Pareto最优解.

定义 3 所有Pareto最优解构成的集合称为Pareto最优解集, 在目标空间的集合称为Pareto前沿记为PF^*.

3.1 基本粒子群算法

基本粒子群算法中, 粒子按以下公式对位置和速度进行更新:

$$\begin{cases}\boldsymbol{v}_i^{t+1}=\omega\boldsymbol{v}_i^t+c_1r_1(\text{pbest}_i^t-\boldsymbol{x}_i^t)+\\\qquad\quad r_2(\text{gbest}_i^t-\boldsymbol{x}_i^t),\\\boldsymbol{x}_i^{t+1}=\boldsymbol{x}_i^t+\boldsymbol{v}_i^t,\end{cases}\tag{7}$$

式中: $\boldsymbol{x}$为粒子位置; $\boldsymbol{v}$为粒子速度; gbest为全局最优解; pbest为个体最优解; ω为惯性因子; c_1, c_2为学习因子; r_1, r_2为区间在$[0,1]$之间的随机数.

3.2 自适应概率引导多目标粒子群算法

传统多目标粒子群算法是将Pareto支配关系与单目标粒子群算法相融合, 其目的为求解出多目标问题的Pareto前沿, 而控制分配问题只需求解出符合期望的单一解. 此外, 传统多目标粒子群算法由于需要较好的Pareto前沿均匀性, 在同等迭代次数下会降低各目标的求解精度. 在本文控制分配问题中, 虚拟控制指令跟踪是最重要的目标, 跟踪精度的下降会极大地影响飞行控制的稳定性. 因此, 本文根据实际需求对多目标粒子群算法做出以下改进.

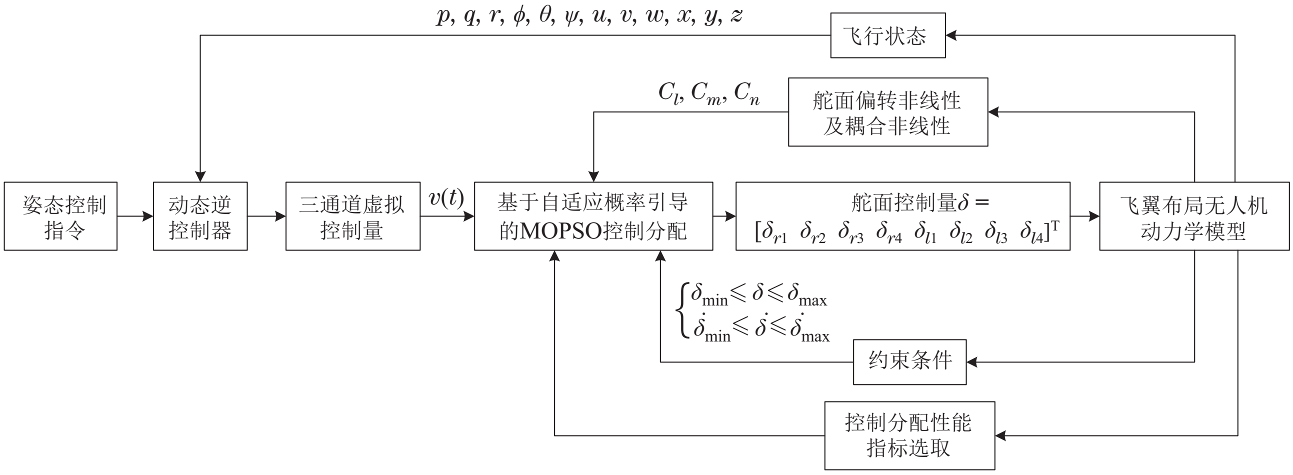

图 4 飞翼式先进布局布局无人机控制策略

Fig. 4 Control strategy of flying wing advanced layout UAV

1) 全局最优解选取策略.

多目标粒子群算法中, 全局最优解的选取将影响算法整体的收敛方向, 最终影响寻优结果中各目标的精度. 本文提出自适应概率引导的动态全局最优解的更新策略, 以使得寻优结果在获得较高指令跟踪精度的同时其余目标均能收敛至期望要求. 具体选取策略如下: 首先, 在第t次迭代得到的外部档案集$\mathrm{Arch}(t)=\{\boldsymbol{x}_1(t),\boldsymbol{x}_2(t),\cdots,\boldsymbol{x}_L(t)\}$中选出使得目标函数$f_1$最优的粒子记为$\boldsymbol{x}_{\min f_1}(t)$, 对应取得的最优值记为$\min f_1(t)$, 筛选出其余$n-1$个目标函数分别最优的粒子记为$\boldsymbol{x}_{\min f_2}(t),\boldsymbol{x}_{\min f_3}(t),\cdots,\boldsymbol{x}_{\min f_n}(t)$, 对应分别取得的最优值记为$\min f_2(t)$, $\min f_3(t),\cdots,\min f_n(t)$. 筛选出的粒子构成候选粒子集$S=\{\boldsymbol{x}_{\min f_1}(t),\boldsymbol{x}_{\min f_2}(t),\cdots,\boldsymbol{x}_{\min f_n}(t)\}$.

其次, 根据得到的各目标函数最优值为$\min f_1(t)$, $\min f_2(t),\cdots,\min f_n(t)$和各目标期望精度$\varepsilon_1,\varepsilon_2,\cdots,\varepsilon_n$计算候选粒子集中各粒子被选中的概率.

从各目标期望精度$\varepsilon_1,\varepsilon_2,\cdots,\varepsilon_n$, 选取其中最大值为基准精度记为$\varepsilon_s$, 即$\varepsilon_s=\max\{\varepsilon_1,\varepsilon_2,\cdots,\varepsilon_n\}$, 计算基准精度与各期望精度的比值

$$r_i=\frac{\varepsilon_s}{\varepsilon_i},\ i\in\{1,2,\cdots,n\}. \tag{8}$$

根据各目标函数最优值是否达到期望精度, 将种群收敛情况分为3个阶段, 不同阶段采用不同的概率确定方式.

a) 各目标函数最优值均未达到期望精度.

各最优粒子选择概率如下:

$$p_{f_i}(t)=\frac{r_i\min f_i(t)-\varepsilon_s}{\sum\limits_{j=1}^{n}[r_j\min f_j(t)-\varepsilon_s]}, \tag{9}$$

其中$r_i\min f_i(t)-\varepsilon_s>0, i\in\{1,2,\cdots n\}$.

b) 部分目标函数最优值达到期望精度.

设有m个函数最优值达到期望精度($0<m<n$), 则各最优粒子选择概率如下:

$$\begin{cases}p_{f_i}(t)=\dfrac{n(r_i\min f_i(t)-\varepsilon_s)}{(n+1)\sum\limits_{j\neq k}[r_j\min f_j(t)-\varepsilon_s]},\\ p_{f_k}(t)=\dfrac{1}{m(n+1)},\end{cases} \tag{10}$$

式中: $r_i\min f_i(t)-\varepsilon_s>0$; $r_k\min f_k(t)-\varepsilon_s\leqslant 0$; 下标$i$表示未达期望的函数; 下标$k$表示已达期望的函数; $i,k\in\{1,2,\cdots,n\}$.

c) 所有目标函数最优值达到期望精度.

各最优粒子选择概率如下:

$$p_{f_i}(t)=\frac{1}{n}r_i\min f_i(t)-\varepsilon_s\leqslant 0, \tag{11}$$

其中$i\in\{1,2,\cdots,n\}$.

最后, 依上一步所计算的概率p_{f_i}, 从候选粒子集S中选取一个粒子作为全局最优解$\mathrm{pbest}(t)$. 根据选择概率p_{f_i}, 计算各粒子累积概率$Q_{f_i}(t)=\sum\limits_{j=1}^{i}p_{f_i}(t)$, $j=\{1,2,\cdots,i\}$; 生成一个$[0,1]$区间内的随机数rand; 比较随机数rand与累积概率Q_{f_i}之间关系, 如果$Q_{f_{i-1}}(t)\leqslant \mathrm{rand}\leqslant Q_{f_i}(t)$则从候选粒子集$S$中选择粒子$\boldsymbol{x}_{\min f_i}(t)$作为全局最优解$\mathrm{pbest}(t)$, 其中定义$Q_{f_0}(t)=0$.

以二维目标为例, 全局最优解的选择策略和种群变化如图5所示. 图中$\varepsilon_1,\varepsilon_2$分别为目标函数$f_1,f_2$期望精度, 所围的阴影区域为粒子目标区域. 种群(1)中目标函数f_2最小值离期望精度ε_2相差较大, 对应粒子a有较大概率被选择为该次迭代的全局最优解gbest, 并引导种群向目标函数f_2值较小的区域收敛; 种群(2)中目标函数f_1最小值离期望精度ε_1相差较大, 对应粒子b有较大概率被选择为该次迭代的全局最优解, 并引导种群向目标函数f_1值较小的区域收敛; 经过多次迭代种群最终被引导收敛至阴影区域, 使得种群中的粒子满足各目标函数的精度要求.

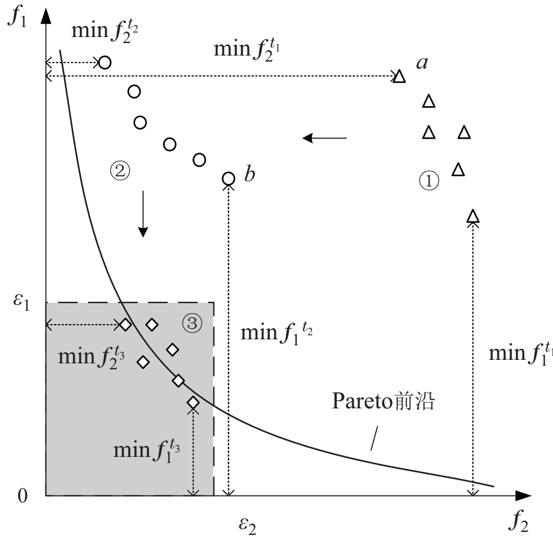

图 5 全局最优解的选择策略和种群变化示意图

Fig. 5 Global optimal selection strategy and population change diagram

2) 粒子变异.

为防止算法过早陷入局部最优解, 即寻优结果未满足控制分配精度要求算法却进入停滞状态, 增加种群粒子变异操作, 使种群跳出局部最优. 在最大迭代次数的二分之一次迭代, 即$t=\lceil\dfrac{T_{\max}}{2}\rceil$开始, 每次迭代寻优中, 除对精度判断外, 增加收敛性指标判断, 若收敛性指标为0,则对粒子群进行变异操作. 具体如下.

首先, 计算前后两次迭代外部档案的收敛性指标

$$D=\sum_{i=1}^{L}\mathrm{dis}(\mathrm{Arch}_i^t,\mathrm{Arch}_i^{t+1})^2,\tag{12}$$

其中: $\mathrm{dis}(\mathrm{Arch}_i^t,\mathrm{Arch}_i^{t-1})$为第$t$次迭代与第$t-1$次迭代得到的外部档案中第$i$个粒子的最小欧式距离; L为第t次迭代外部档案中的粒子数.

其次, 判断收敛性指标D是否为0. 当收敛性指标D为0时, 对粒子当前位置进行变异操作, 即$\boldsymbol{x}'=(1+\varDelta)\boldsymbol{x}$, 其中$\varDelta$为变异因子, 具体表达式如下:

$$\varDelta=\begin{cases}\dfrac{1}{(2u)^3}-1, & u<0.5,\\ 1-[2(1-u)]^{\frac{1}{3}}, & u\geqslant 0.5,\end{cases}\tag{13}$$

其中$u=\mathrm{rand}(0,1)$.

最后, 对变异后违反约束的粒子进行修正, 具体修正为边界值.

3.3 算法流程

基于自适应概率引导的多目标粒子群算法流程如下:

步骤 1　设置算法参数. 初始化粒子群, 对每个粒子, 确定其初始位置和初始速度, 粒子的初始个体最优解设置为粒子本身.

步骤 2　计算粒子群中各粒子的目标函数, 根据Pareto支配关系, 将非支配解存入外部档案.

步骤 3　根据改进的选取方法, 在外部档案中选取全局最优解, 按粒子群算法的基本公式更新粒子位置和速度.

步骤 4　按上节方法进行变异操作. 并计算新粒子群中每个粒子的目标函数.

步骤 5　依据前后两代粒子间Pareto支配关系更新个体最优解, 保留支配解, 若互相非支配, 则随机保留一个粒子.

步骤 6　将新粒子群中非支配解存入外部档案, 删除外部档案中被支配的粒子. 若更新后外部档案中粒子数大于档案规模, 则根据密集度原则, 保留密集度大的粒子删除密集度小的粒子, 直至满足规模要求.

步骤 7　从外部档案中选取输出粒子, 判断是否满足结束条件, 即达到最大迭代次数或输出粒子各目标函数均满足要求, 若满足则输出结果, 否则转至步骤3.

4 收敛性及稳定性分析

4.1 自适应概率引导多目标粒子群算法收敛性分析

定义 4　设A_r为算法外部档案, 对应目标空间集为$F(A_r)$. 定义$\varPhi$为由$F(A_r)$的插值超曲面及其左下方的目标空间所包围的区域, 对应勒贝格测度表示为ρ_{A_r}. 设$\varOmega$为多目标问题Pareto最优解集, 其勒贝格测度表示为ρ_{Ω}. 定义收敛度为$D(A_r^t)=|\rho_{A_r^t}-\rho_{\Omega}|$, 其中$A_r^t$为迭代次数为$t$时的外部档案.

定义 5　若算法以概率1全局收敛至最优解集$\varOmega$, 当且仅当$P\{\lim\limits_{t\to\infty}D(A^{(t)})=0\}=1$.

结合文献[21], 给出以下引理

引理 1　设$\{X^t,t=1,2,\cdots\}$是一个随机序列. 如果$P\{\lim\limits_{t\to\infty}X^t=0\}=1$当且仅当对于$\forall\varepsilon>0$均有$\sum\limits_{t=1}^{+\infty}P\{|X^t|\geqslant\varepsilon\}<+\infty$.

引理 2　对于多目标粒子群算法, 假设决策空间是可行域R上的紧集, 各目标函数$f(x)$连续, 设$\{A_r^t;t=1,2,\cdots\}$为未增加变异操作的多目标算法生成的外部档案序列. 对于$\forall\varepsilon>0$, 存在正整数$N>1$使得

1) 当$t\leqslant N$时, 存在$0<\eta\leqslant 1$使得

$$P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon)\}\geqslant\eta;$$

2) 当$t>N$时, 存在

$$P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon\}=0.$$

定理 1　自适应概率引导多目标算法其收敛度序列$\{D(A_r^t),t=1,2,\cdots\}$在$t\to\infty$时以概率1收敛至0, 即以概率1全局收敛至Pareto最优解集.

证 首先, 证明本文提出自适应概率引导多目标算法若不增加变异操作可使引理2成立.

1) 设Θ为PF^*, $F(A_r^t)$的插值超曲面和目标空间边界所围成的区域. 如果$D(A_r^t)\geqslant\varepsilon$则候选粒子集$S=\{\boldsymbol{x}_{\min f_1}(t),\boldsymbol{x}_{\min f_2}(t),\cdots,\boldsymbol{x}_{\min f_n}(t)\}$中至少存在一个粒子$\boldsymbol{x}^*\notin\Omega$. 根据第3.2节全局最优解gbest选取策略, $\boldsymbol{x}^*$会以确定的概率被选择成为gbest. 由此根据更新式(7)存在一个新粒子$\boldsymbol{x}$由$\boldsymbol{x}^*$生成, 同时由于粒子更新速度$\|\boldsymbol{v}\|_2\neq0$, 则$\boldsymbol{x}$以确定概率进入区域$\Theta$. 此时存在两种情况: $F(\boldsymbol{x})\prec F(\boldsymbol{x}^*)$或$F(\boldsymbol{x})\not\prec\succ F(\boldsymbol{x}^*)$, 其中$\prec\succ$表示互不支配. 根据第3.3节外部档案维护策略, 当$F(\boldsymbol{x})\prec F(\boldsymbol{x}^*)$时, 新粒子$\boldsymbol{x}$替代$\boldsymbol{x}^*$加入外部档案, 当$F(\boldsymbol{x})\prec\succ F(\boldsymbol{x}^*)$时, 新粒子$\boldsymbol{x}$直接加入外部档案. 由此无论哪一种情况, 从全局最优解gbest选取, 到新粒子$\boldsymbol{x}$加入外部档案A_r^{t+1}的概率均为正, 表示为P_ε. 相应的$F(A_r^t)$的插值超曲面以概率P_ε更逼近PF^*. 从而, 对于候选粒子集S中n个粒子均有概率$P_{\varepsilon i}, i=1,2,\cdots,n$使得$F(A_r^t)$的插值超曲面更逼近$PF^*$. 设$P_{\varepsilon m}=\min\{P_{\varepsilon1},P_{\varepsilon2},\cdots,P_{\varepsilon n}\}$, 则有

$$P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon)\}\geqslant(P_{\varepsilon m})^n=\eta>0$$

成立.

2) 当$t>N$时, 如果$D(A_r^{t-1})\geqslant\varepsilon$, 可能会出现以下一种情况: $A_r^{t-1}\cap\Omega=\varnothing$并且在第$t$次迭代$A_r^t$中存在粒子gbest*支配$A_r^{t-1}$中所有粒子, 根据第3.3节外部档案维护策略此时$A_r^t$中仅有gbest*一个粒子, 从而gbest*必定被选择成为全局最优解. 此外, 由gbest*生成的所有新粒子仍被gbest*支配. 则在这种情况下gbest*一直为所有粒子的全局最优解. 根据文献[22]可知, 当满足条件

$$\frac{1}{2}|(1+\omega-\frac{c_1+c_2}{2})\pm\sqrt{(1+\omega-\frac{c_1+c_2}{2})^2-4\omega}|<1$$

时,

$$\hat{\boldsymbol{x}}=\lim_{t\to\infty}E[\boldsymbol{x}_i(t)]=\frac{c_1\mathrm{pbest}_i+c_2\mathrm{gbest}}{c_1+c_2}.$$

由于当$t>N$时gbest*一直为所有粒子的全局最优解, 则随着迭代次数增加, 各粒子均会向gbest*逼近, 即, $\lim\limits_{t\to\infty}\boldsymbol{x}_i(t)=\mathrm{gbest}^*$, $\lim\limits_{t\to\infty}\boldsymbol{v}_i(t)=0$. 由此, 当$t>N$时, 所有粒子均停滞于gbest$^*\notin\Omega$. 若$D(A_r^t)\geqslant\varepsilon$, 则$D(A_r^{t+1})=D(A_r^t)\geqslant\varepsilon$. 由此, $P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon\}=0$成立.

故, 根据式(1)(2)可知不增加变异操作的自适应概率引导多目标算法可使引理2成立.

其次, 首先考虑无变异操作算法全局收敛性情况.

1) 当在第t^*次迭代$D(A_r^{t^*})=0$时, 由于收敛度非增, 则对于$\forall t>t^*$, 均有$D(A_r^t)=0$. 因此,

$$P\{\lim_{t\to\infty}D(A_r^t)=0\}=1.$$

2) 当在t次迭代$D(A_r^t)\geqslant\varepsilon$时, 由于收敛度非增, 则有

$$\begin{aligned}&P\{D(A_r^{t+1})\geqslant\varepsilon\}=\\&P\{D(A_r^t)\geqslant\varepsilon\}P\{D(A_r^{t+1})\geqslant\varepsilon|D(A_r^t)\geqslant\varepsilon\}=\\&P\{D(A_r^{t-1})\geqslant\varepsilon\}P\{D(A_r^t)\geqslant\varepsilon|D(A_r^{t-1})\geqslant\varepsilon\}\\&P\{D(A_r^{t+1})\geqslant\varepsilon|D(A_r^t)\geqslant\varepsilon\}=\cdots=\\&P\{D(A_r^1)\geqslant\varepsilon\}\prod_{i=1}^{t}P\{D(A_r^{i+1})\geqslant\varepsilon|D(A_r^i)\geqslant\varepsilon\}.\end{aligned}\tag{14}$$

根据引理2中$P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon)\}\geqslant\eta$可得$P\{D(A_r^{t+1})\geqslant\varepsilon\}\leqslant P\{D(A_r^1)\geqslant\varepsilon\}(1-\eta)^t$, 累加得

$$\begin{aligned}&\sum_{t=1}^{N}P\{D(A_r^{t+1})\geqslant\varepsilon\}\leqslant\\&P\{D(A_r^1)\geqslant\varepsilon\}\sum_{t=1}^{N}(1-\eta)^t=\\&P\{D(A_r^1)\geqslant\varepsilon\}\frac{1-\eta}{\eta}(1-(1-\eta)^N).\end{aligned}\tag{15}$$

以下讨论两种情况:

1) 当$N\to\infty$时,

$$\begin{aligned}&\sum_{t=1}^{\infty}P\{D(A_r^{t+1})\geqslant\varepsilon\}\leqslant\\&P\{D(A_r^1)\geqslant\varepsilon\}\frac{1-\eta}{\eta}<\infty.\end{aligned}\tag{16}$$

根据引理1可知$P\{\lim\limits_{t\to\infty}D(A_r^t)=0\}=1$.

2) 当N为确定正整数时, 根据引理2, 当$t>N$时, $P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon\}=0$, 即$P\{D(A_r^{t+1})\geqslant\varepsilon|D(A_r^t)\geqslant\varepsilon\}=1$; 当$t\leqslant N$时, $P\{D(A_r^{t+1})<\varepsilon|D(A_r^t)\geqslant\varepsilon)\}\geqslant\eta\geqslant0$.

当$t\leqslant N$时,

$$\begin{aligned}&\sum_{t=1}^{N}P\{D(A_r^{t+1})\geqslant\varepsilon\}\leqslant\\&P\{D(A_r^1)\geqslant\varepsilon\}\frac{1-\eta}{\eta}(1-(1-\eta)^N)<\infty.\end{aligned}\tag{17}$$

当$t>N$时,

$$\begin{aligned}&P\{D(A_r^{t+1})\geqslant\varepsilon\}=\\&P\{D(A_r^1)\geqslant\varepsilon\}\prod_{i=1}^{t}P\{D(A_r^{i+1})\geqslant\varepsilon|D(A_r^i)\geqslant\varepsilon\}=\\&P\{D(A_r^1)\geqslant\varepsilon\}\\&\prod_{i=1}^{N}P\{D(A_r^{i+1})\geqslant\varepsilon|D(A_r^i)\geqslant\varepsilon\}\\&\prod_{i=N+1}^{t}P\{D(A_r^{i+1})\geqslant\varepsilon|D(A_r^i)\geqslant\varepsilon\}=\\&P\{D(A_r^1)\geqslant\varepsilon\}\end{aligned}$$

$$\prod_{i=1}^{N} P\{D(A_r^{i+1}) \geqslant \varepsilon | D(A_r^i) \geqslant \varepsilon\} =$$
$$P\{D(A_r^1) \geqslant \varepsilon\}$$
$$\prod_{i=1}^{N}(1 - P\{D(A_r^{i+1}) < \varepsilon | D(A_r^i) \geqslant \varepsilon\}) =$$
$$C > 0. \tag{18}$$

则

$$\sum_{t=N+1}^{\infty} P\{D(A_r^{t+1}) \geqslant \varepsilon\} = \infty. \tag{19}$$

由此可得,

$$\begin{aligned}&\sum_{t=1}^{\infty} P\{D(A_r^{t+1}) \geqslant \varepsilon\} = \\ &\sum_{t=1}^{N} P\{D(A_r^{t+1}) \geqslant \varepsilon\}+ \\ &\sum_{t=N+1}^{\infty} P\{D(A_r^{t+1}) \geqslant \varepsilon\} = \infty.\end{aligned} \tag{20}$$

此结果不满足引理1,即$P\{\lim\limits_{t\to\infty} D(A_r^t) = 0\} \neq 1$. 由此可得, 没有变异操作的多目标粒子群算法不能保证当$t \to \infty$时, 收敛度序列以概率1收敛至0, 即无法保证全局收敛至最优解集.

最后证明增加变异操作后本文算法具有全局收敛性. 由第3.2节中的变异操作可知根据变异因子$\varDelta$可得变异后粒子$\boldsymbol{x}' = (1 + \varDelta)\boldsymbol{x}$. 设事件$B_1$为变异前粒子$\boldsymbol{x}$进入区域$\varTheta$, B_2为变异后粒子$\boldsymbol{x}'$进入区域$\varTheta$. 则, 新粒子进入区域$\varTheta$的概率为$P(B_1 \cup B_2)$. 根据变异因子的确定方式可知, $\boldsymbol{x}'$以确定的概率$P_\Delta > 0$进入区域$\varTheta$, 即$P(B_2) = P_\Delta > 0$. 而

$$P(B_1 \cup B_2) = P(B_1) + P(B_2) - P(B_1 \cap B_2)$$

并且$P(B_1) \geqslant P(B_1 \cap B_2)$, 则$P(B_1 \cup B_2) \geqslant P(B_2) > 0$. 因此, 由于增加的变异操作, 所有粒子不可能均停滞于同一位置, 引理2中的情况2)不可能出现. 仅存在情况1)且$N \to \infty$, 即, 对于$\forall \varepsilon > 0$, 当$t > 0$时, 存在$0 < \eta \leqslant 1$使得$P\{D(A_r^{t+1}) < \varepsilon | D(A_r^t) \geqslant \varepsilon)\} \geqslant \eta$.

由此可得,

$$\begin{aligned}&\sum_{t=1}^{\infty} P\{D(A_r^{t+1}) \geqslant \varepsilon\} = \\ &P\{D(A_r^1) \geqslant \varepsilon\}\frac{1-\eta}{\eta}(1 - (1-\eta)^N) \leqslant \\ &P\{D(A_r^1) \geqslant \varepsilon\}\frac{1-\eta}{\eta} < \infty.\end{aligned} \tag{21}$$

根据引理1可知自适应概率引导多目标算法其收敛度序列$\{D(A_r^t), t = 1, 2, \cdots\}$在$t \to \infty$时以概率1收敛至0, 即以概率1全局收敛至Pareto最优解集.

证毕.

4.2 控制算法稳定性分析

根据时标分离原理将控制系统划分为内外两个回路, 外回路选取状态变量为姿态角$\boldsymbol{x}_1 = [\phi\ \ \theta\ \ \psi]^{\mathrm{T}}$, 内回路选取状态变量为姿态角速度$\boldsymbol{x}_2 = [p\ \ q\ \ r]^{\mathrm{T}}$. 则系统状态方程可以描述为

$$\begin{cases}\dot{\boldsymbol{x}}_1 = f_1(\boldsymbol{x}_1) + g_1(\boldsymbol{x}_1)\boldsymbol{x}_2, \\ \dot{\boldsymbol{x}}_2 = f_2(\boldsymbol{x}_2) + g_2(\boldsymbol{x}_2)(\boldsymbol{v} + \boldsymbol{\xi}), \\ \boldsymbol{y} = [\boldsymbol{x}_1\ \ \boldsymbol{x}_2]^{\mathrm{T}},\end{cases} \tag{22}$$

式中: $\boldsymbol{v}$为虚拟控制指令, 具体形式如式(4); $\boldsymbol{\xi}$为控制分配误差.

对于外回路, 将动态逆控制律$\boldsymbol{x}_2 = g_1^{-1}(\boldsymbol{x}_1)\ [\omega_s \cdot (\boldsymbol{x}_{1c} - \boldsymbol{x}_1) - f_1(\boldsymbol{x}_1)]$带入得

$$\dot{\boldsymbol{x}}_1 = \boldsymbol{\omega}_s(\boldsymbol{x}_{1c} - \boldsymbol{x}_1), \tag{23}$$

其中: $\boldsymbol{x}_{1c}$为姿态角控制指令; $\boldsymbol{\omega}_s$为对角矩阵, 对角元素为外回路各通道频带值. 当对角元素均取正数时, 矩阵$-\boldsymbol{\omega}_s$所有特征值均具有负实部, 则外回路系统是稳定的.

对于内回路, 将动态逆控制律$\boldsymbol{v} = g_2^{-1}(\boldsymbol{x}_2)\ [\omega_f \cdot (\boldsymbol{x}_{2c} - \boldsymbol{x}_2) - f_2(\boldsymbol{x}_2)]$带入得

$$\begin{aligned}\dot{\boldsymbol{x}}_2 = &\boldsymbol{\omega}_f(\boldsymbol{x}_{2c} - \boldsymbol{x}_2) + g_2(\boldsymbol{x}_2)\boldsymbol{\xi} = \\ &-\boldsymbol{\omega}_f\boldsymbol{x}_2 + \boldsymbol{\omega}_f\boldsymbol{x}_{2c} + g_2(\boldsymbol{x}_2)\boldsymbol{\xi},\end{aligned} \tag{24}$$

其中: 控制分配误差$\boldsymbol{\xi}$由多目标粒子群寻优结果决定, 根据上一节算法收敛性分析可知, 自适应概率引导多目标算法具有全局收敛性, 则控制分配误差$\boldsymbol{\xi}$有界且全局收敛. 并且对于飞控系统$g_2(\boldsymbol{x}_2)$有界, 则有下式成立:

$$\|\dot{\boldsymbol{x}}_2 + \boldsymbol{\omega}_f x_2\| = \|\boldsymbol{\omega}_f\boldsymbol{x}_{2c} + g_2(\boldsymbol{x}_2)\boldsymbol{\xi}\| < R, \tag{25}$$

其中R为一正实数. 根据上式则有以下条件成立:

$$\begin{cases}\dot{x}_i < 0,\ \forall x_i > \dfrac{R}{\omega_{fi}}, \\ \dot{x}_i > 0,\ \forall x_i < -\dfrac{R}{\omega_{fi}}.\end{cases} \tag{26}$$

由上式可得

$$\|x_i\| \leqslant \frac{R}{\omega_{fi}}. \tag{27}$$

因此系统状态量$\boldsymbol{x}_2$有界, 且当$\boldsymbol{\xi} \to 0$时$\boldsymbol{x}_2 \to \boldsymbol{x}_{2c}$.

5 仿真验证与结果分析

针对飞翼式先进布局无人机非线性模型, 在仿真环境下验证本文所提出的基于自适应概率引导多目标算法的控制分配方法的有效性.

各舵面偏转角度范围约束为

$$\begin{cases}\boldsymbol{\delta}_{\min}(t) = \\ [-20\ \ -20\ \ -20\ \ 0\ \ -20\ \ -20\ \ -20\ \ 0], \\ \boldsymbol{\delta}_{\max}(t) = [20\ \ 20\ \ 20\ \ 90\ \ 20\ \ 20\ \ 20\ \ 90].\end{cases}$$

各舵面偏转角速率约束均为: $[-100, 100]$.

给定滚转偏航俯仰通道各5°指令, 由控制器生成

三通道虚拟控制指令, 采用本文提出的自适应概率引导的多目标算法进行在线控制分配. 设定虚拟控制指令跟踪误差、舵面偏转量最小和舵面平滑偏转三性能指标, 各目标函数期望精度为$\varepsilon_1=10^{-7}$, $\varepsilon_2=1$, $\varepsilon_3=0.1$, 算法参数设置为: 种群规模$N=60$, 外部档案存储规模$AN=30$, 最大迭代次数$T_{\max}=100$, 学习因子$c_1=1$, $c_1=2$, 初始惯性权重因子$\omega_0=1.4$, 末惯性权重因子$\omega_{\rm end}=0.4$, 仿真时长5 s, 仿真固定步长20 ms.

为验证本算法的有效性, 将本文方法与文献[12]提出Ra-MOPSO算法进行对比. 其中, 设定Ra-MOPSO算法参数为: 参考点设置为期望精度点$g=[10^{-7}, 1, 0.1]$, 阈值$\delta=0.5$, 其余参数与本文方法设置相同. 仿真曲线如图6–7所示.

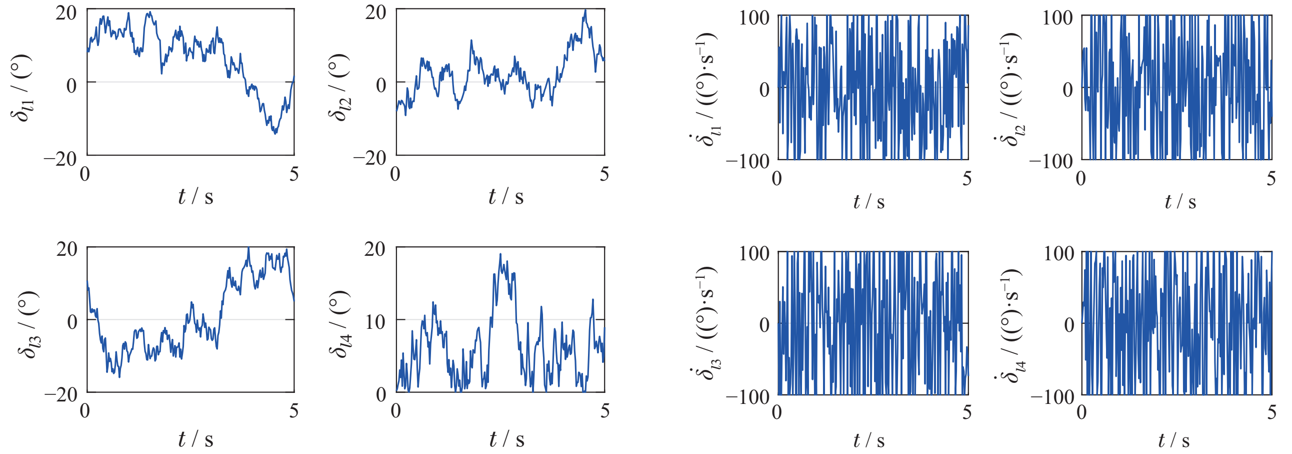

(a) Ra-MOPSO算法

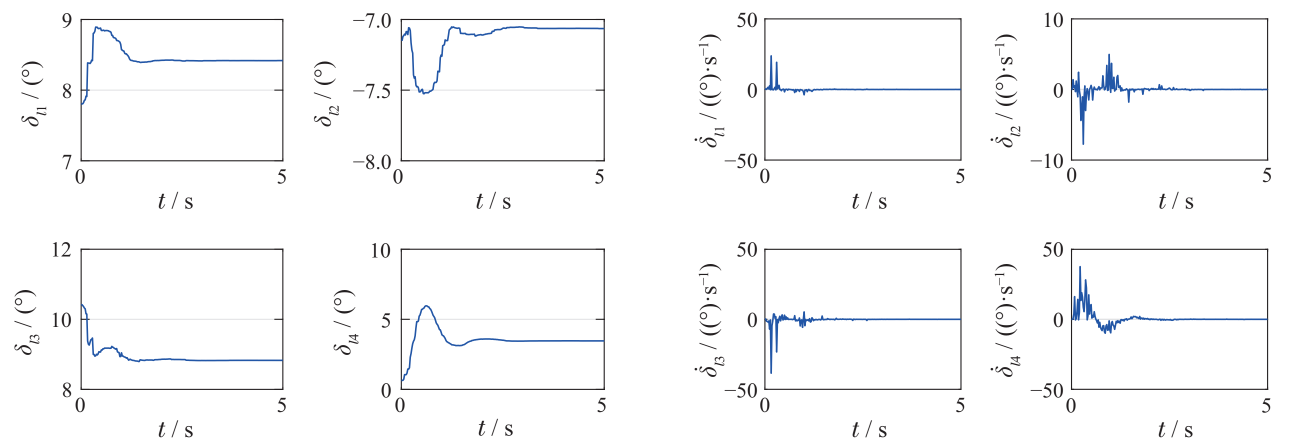

(b) 本文方法

图 6 左侧各舵面偏转指令及指令变化率

Fig. 6 Deflection command and command change rate of each rudder surface on the left

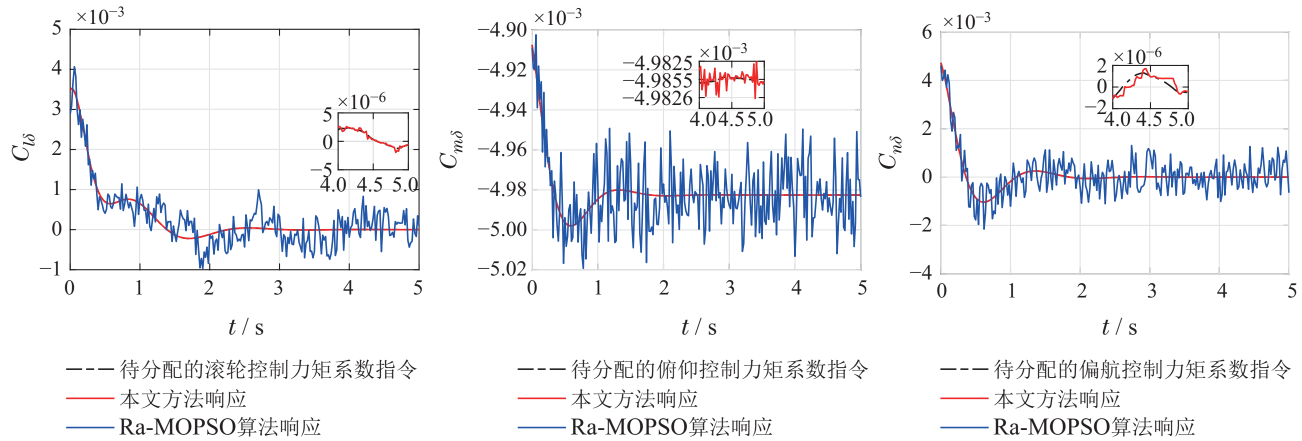

(a) 虚拟控制指令跟踪响应

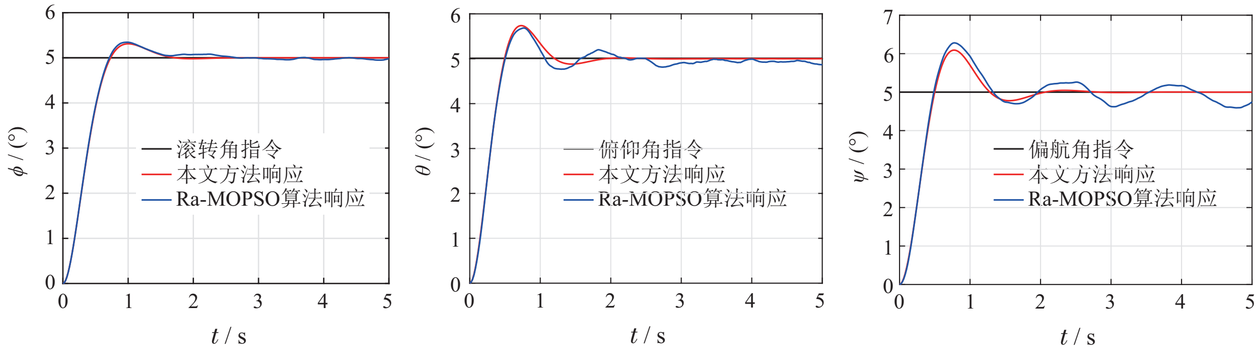

(b) 姿态度响应

图 7　虚拟控制指令跟踪响应及姿态角响应

Fig. 7　Virtual control command tracking response and attitude angle response

图6(a)和图6(b)为左侧各舵面偏转指令以及指令变化率曲线. 对比可以看出, 采用本文方法分配得到的各舵面偏转更为平滑. 而采用Ra-MOPSO算法控制分配解算出的舵面偏转速率更大, 舵面抖振剧烈.

图7为虚拟控制指令跟踪响应和系统状态响应曲线, 虚拟控制指令跟踪响应图中增加4~5 s本文方法局部放大图, 可以看出, 采用本文方法实际控制量跟虚拟控制指令之间相差较少, 说明各舵面偏转所产生的控制力矩系数可以较好地跟踪期望的虚拟控制指令; 而采用Ra-MOPSO算法对虚拟控制指令的跟踪精度较差. 由系统状态响应曲线, 可以看出, 相较于Ra-MOPSO算法, 采用本文方法系统可以较好地跟踪姿态控制指令, 控制分配效果良好.

图8为2 s时刻采用Ra-MOPSO算法搜索得到的外部档案与种群粒子分布. 可以看出种群粒子呈带状分布, 这是由于Ra支配规则是基于所设定的参考向量得到的, 因此种群粒子围绕参考向量形成带状分布; 图9为采用本文搜索得到的外部档案与种群粒子分布. 可以看出有较多的粒子集中在某一区域, 但仍具有一定的均匀程度. 其中密集区域粒子的目标函数值具有较高的精度, 这是由于采用本文方法更偏好有较高精度需求的目标函数, 搜索过程中粒子种群会在该目标区域精细搜索, 最终搜索至外部档案中某一粒子满足各目标精度要求.

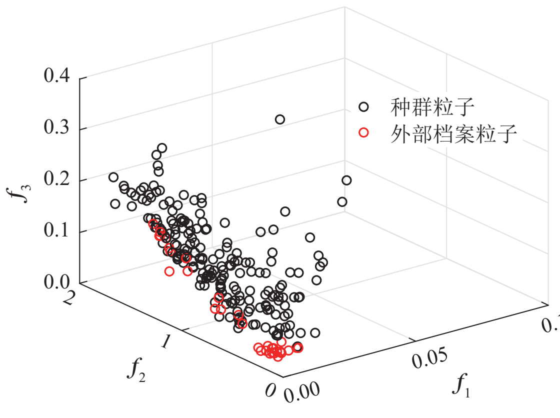

图 8　Ra-MOPSO算法外部档案与种群粒子分布

Fig. 8　External profile and population particle distribution of Ra-MOPSO algorithm

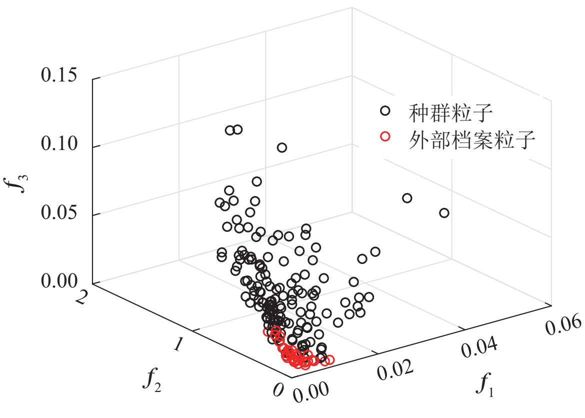

图 9　本文方法外部档案与种群粒子分布

Fig. 9　External profile and population particle distribution of this method

最后验证算法运算时间, 本文仿真实验在Intel Core i7–9700 CPU@3.00 GHz的环境下进行, 提出的自适应概率引导多目标粒子群算法作为一种群智能算法, 其运算时间受种群规模影响较大, 因此分别设定种群规模为$N = 30$, $N = 60$, $N = 120$的3组实验进行对比分析. 考虑单次分配的偶然性, 因此给定相同待分配控制力矩系数, 独立重复1000次分配运算, 以验证算法时效性. 3组算法除种群规模不同外, 其余参数均相同. 仿真结果为: 种群规模$N = 30$算法, 1000次分配运算总时间为19.71 s, 平均单次分配时间为19.71 ms; $N = 60$种群规模算法, 1000次分配运算时间为15.51 s, 平均单次分配时间为15.51 ms; 种群规模$N = 120$算法, 1000次分配运算时间为17.15 s, 平均单次分配时间为17.15 ms. 仿真结果表明如上种群规模下本文算法能够满足实时飞行控制的要求. 另, 从仿真时间可以看出种群规模$N = 60$时运算时间最

短, 这是由于当种群规模过小时, 会导致群体寻优能力不足, 需要较高的迭代次数来寻找到期望精度点; 而种群规模过大时, 则会增大单次迭代运算复杂度, 增加单次迭代运算时间, 虽可降低寻优总迭代次数, 但整体运算时间反而增加. 因此, 适中的种群规模可以有效降低算法运算时间.

6 结论

本文研究了一类飞翼式先进布局无人机控制分配问题. 飞翼式的气动构型使得舵面之间气动耦合增强, 此外舵面偏转与控制力矩系数并非完美线性关系, 这导致在控制分配时必须要考虑舵面非线性特性. 对此本文建立控制分配非线性模型, 将控制分配问题看作多目标优化问题, 提出一种自适应概率引导多目标粒子群算法, 根据虚拟控制指令在线求取各舵面偏转指令. 该算法根据各目标重要程度动态改变各目标最优粒子被选择为全局最优粒子的概率, 从而快速引导算法求解出符合控制分配要求的舵面偏转指令. 通过仿真验证得到: 相较于经典多目标粒子群算法, 本文方法具有更高的分配精度, 有利于无人机精确响应控制指令; 更小的舵面偏转角速率, 控制更平滑, 有利于减少舵面偏转磨损提高使用寿命. 兼顾控制分配精确性的情况下, 满足工程实用性.

参考文献:

[1] LEI W, LI X. Reconfigurable flight control design for combat flying wing with multiple control surfaces. *Chinese Journal of Aeronautics*, 2012, 25(4): 493 – 499.

[2] TOMAC M, STENFELT G. Predictions of stability and control for a flying wing. *Aerospace Science & Technology*, 2014, 39: 179 – 186.

[3] MA Jianjun, ZHENG Zhiqiang, HU Dewen. Subspace predictive dynamic control allocation method including actuator dynamics. *ACTA Automatica Sinica*, 2010, 36(1): 130 – 138.
(马建军, 郑志强, 胡德文. 包含执行器动力学的子空间预测动态控制分配方法. 自动化学报, 2010, 36(1): 130 – 138.)

[4] ZHENG F, LIU L, CHEN Z, et al. Hybrid multi-objective control allocation strategy for compound high-speed rotorcraft. *ISA Transactions*, 2020, 98: 207 – 226.

[5] LU Yao, DONG Chaoyang, WANG Qing, et al. Control allocation for distributed driving morphing aircraft with integer constraints. *Control Theory & Applications*, 2018, 35(8): 1083 – 1091.
(路遥, 董朝阳, 王青, 等. 存在整数约束的分布式驱动变体飞行器控制分配. 控制理论与应用, 2018, 35(8): 1083 – 1091.)

[6] YAN Y, YANG J, LIU C, et al. On the actuator dynamics of dynamic control allocation for a small fixed-wing uav with direct lift control. *IEEE Transactions on Control Systems Technology*, 2020, 28(3): 984 – 991.

[7] SEYED S, YILDIARY Y, ILYA K. Adaptive control allocation for constrained systems. *Automatica*, 2020, 121: 109161.

[8] CHEN L, CHRISTOPHER E, HALIM A, et al. Flight evaluation of a sliding mode online control allocation scheme for fault tolerant control. *Automatica*, 2020, 114: 108829.

[9] ZHANG Bo, ZHU Xiaoping, ZHOU Zhou, et al. Attitude control of flying wing UAV with input constraints. *Control Theory & Applications*, 2015, 32(6): 725 – 733.
(张波, 祝小平, 周洲, 等. 输入有约束时的飞翼布局无人机姿态控制. 控制理论与应用, 2015, 32(6): 725 – 733.)

[10] KOLARRIC P, LOPEZ V, LEWIS F. Optimal dynamic control allocation with guaranteed constraints and online reinforcement learning. *Automatica*, 2020, 122: 109265.

[11] QU X, ZHANG W, SHI J, et al. A novel yaw control method for flying-wing aircraft in low speed regime. *Aerospace Science and Technology*, 2017, 69: 636 – 649.

[12] ZHANG S, MENG Q. An anti-windup INDI fault-tolerant control scheme for flying wing aircraft with actuator faults. *ISA Transactions*, 2019, 93: 172 – 179.

[13] WANG Liping, FENG Meiling, QIU Qicang, et al. Review of preference multi-objective evolutionary algorithms. *Journal of Computer Science*, 2019, 42(6): 1289 – 1315.
(王丽萍, 丰美玲, 邱启仓, 等. 偏好多目标进化算法研究综述. 计算机学报, 2019, 42(6): 1289 – 1315.)

[14] DAI C, WANG W, YE M. A new multi-objective particle swarm optimization algorithm based on decomposition. *Information Sciences*, 2015, 325: 541 – 557.

[15] YU X, CHEN W, GU T, et al. Set-based discrete particle swarm optimization based on decomposition for permutation-based multiobjective combinatorial optimization problems. *IEEE Transactions on Cybernetics*, 2018, 48(7): 2139 – 2153.

[16] HU W, YEN G. Optimization based on parallel cell coordinate system. *IEEE Transactions on Evolutionary Computation*, 2015, 19(1): 1 – 18.

[17] LI L, CHANG L, GU T, et al. On the norm of dominant difference for many-objective particle swarm optimization. *IEEE Transactions on Cybernetics*, 2021, 51(4): 2055 – 2067.

[18] YU Weiwei, XIE Chengwang, BI Yingzhou, et al. A high-dimensional multi-objective particle swarm optimization algorithm based on adaptive fuzzy domination. *ACTA Automatica Sinica*, 2018, 44(12): 2278 – 2289.
(余伟伟, 谢承旺, 闭应洲, 等. 一种基于自适应模糊支配的高维多目标粒子群算法. 自动化学报, 2018, 44(12): 2278 – 2289.)

[19] ZHAN Z, LI J, CAO J, et al. Multiple populations for multiple objectives: A coevolutionary technique for solving multiobjective optimization problems. *IEEE Transactions on Cybernetics*, 2013, 43(2): 445 – 463.

[20] ZOU J, YANG Q, YANG S, et al. Ra-dominance: A new dominance relationship for preference-based evolutionary multiobjective optimization. *Applied Soft Computing*, 2020, 90: 106192.

[21] XU G, LUO K, JING G, et al. On convergence analysis of multi-objective particle swarm optimization algorithm. *European Journal of Operational Research*, 2020, 286(1): 32 – 38.

[22] JIANG M, LOU Y, YANG S. Stochastic convergence analysis and parameter selection of the standard particle swarm optimization algorithm. *Information Processing Letters*, 2007, 102(1): 8 – 16.

作者简介:

郑峰婴 副教授, 研究方向为飞行器先进控制技术、复杂系统重构控制技术等, E-mail: zhfy@nuaa.edu.cn;

王 峰 硕士研究生, 研究方向为飞行器智能控制技术, E-mail: 1138684050@qq.com;

甄子洋 教授, 研究方向为舰载机着舰引导与控制、无人机集群编队协同控制与决策等, E-mail: zhenziyang@nuaa.edu.cn;

许梦园 硕士研究生, 研究方向为飞行器容错控制技术, E-mail: xmyyolanda@163.com;

范 涛 硕士研究生, 研究方向为飞行器非线性控制技术, E-mail: ae1243810809@126.com.