

# 基于模型无关元学习-序列凸优化的飞行器在线轨迹重规划

李佳仪<sup>1</sup>, 周彬<sup>1,2†</sup>, 付艳明<sup>1</sup>

(1. 哈尔滨工业大学 航天学院, 哈尔滨 150000; 2. 哈尔滨工业大学 郑州高等研究院, 郑州 450000)

**摘要:** 针对高速巡航飞行器在线重规划面临的计算实时性差、环境适应性弱、控制平滑性不足等问题, 提出一种基于模型无关元学习 (MAML) 热启动序列凸优化 (SCO) 的在线轨迹重规划方法. 首先, 建立飞行器三自由度动力学模型, 并利用 hp-自适应伪谱法构建包含多样化避障场景的高质量离线最优轨迹库; 其次, 融合最近邻残差搭建内外层循环的 MAML 训练框架, 通过学习离线轨迹库蕴含的动力学流形与拓扑特征, 获取最优公共初始参数, 使网络仅需少量梯度更新, 即可快速适应新环境并生成高质量初值; 最后, 建立基于 MAML 热启动 SCO 的在线轨迹重规划框架, 利用 MAML 的自学习、自适应能力快速推导出新环境下的 SCO 热启动初值, 使 SCO 求解器在极少次迭代内收敛. 经仿真验证, 所提出方法在面对新威胁环境时, 能够同时兼顾规划效率与控制平滑性, 实时规划出满足动力学约束的平滑避障轨迹.

**关键词:** 高速巡航飞行器; 在线轨迹规划; 模型无关元学习; 序列凸优化; 伪谱法; 热启动

**中图分类号:** TP273 **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2026.0071

**引用格式:** 李佳仪, 周彬, 付艳明. 基于模型无关元学习-序列凸优化的飞行器在线轨迹重规划 [J]. 控制与决策.

## Online aircraft trajectory replanning via model-agnostic meta-learning and sequential convex optimization

LI Jia-yi<sup>1</sup>, ZHOU Bin<sup>1,2†</sup>, FU Yan-ming<sup>1</sup>

(1. School of Astronautics, Harbin Institute of Technology, Harbin 150000, China; 2. Zhengzhou Advanced Research Institute, Harbin Institute of Technology, Zhengzhou 450000, China)

**Abstract:** To address the challenges of poor real-time computation, weak environmental adaptability, and insufficient control smoothness in the online replanning of high-speed cruising vehicles, this paper proposes a novel online trajectory replanning method based on model-agnostic meta-learning (MAML) warm-started sequential convex optimization (SCO). First, a three-degree-of-freedom (3-DOF) dynamic model of the vehicle is established, and a high-quality offline optimal trajectory library containing diverse obstacle avoidance scenarios is constructed using the hp-adaptive pseudospectral method. Second, a MAML training framework with inner and outer loops is constructed by incorporating nearest-neighbor residuals. By learning the dynamic manifolds and topological features inherent in the offline trajectory library, optimal common initialization parameters are obtained, enabling the network to rapidly adapt to new environments and generate high-quality initial values with only a few gradient updates. Finally, an online trajectory replanning framework based on MAML warm-starting SCO is established. Leveraging the self-learning and adaptive capabilities of MAML, the framework quickly infers warm-start initial values for SCO in new environments, enabling the SCO solver to converge within very few iterations. Simulation results demonstrate that when facing new threat environments, the proposed method effectively balances planning efficiency with control smoothness, and can dynamically plan smooth obstacle avoidance trajectories that satisfy the dynamic constraints in real time.

**Keywords:** high-speed cruise vehicle; online trajectory planning; model-agnostic meta-learning; sequential convex optimization; pseudospectral method; warm start

## 0 引言

高速巡航飞行器具有高突防、快响应、战术机动

灵活的特点<sup>[1]</sup>, 在对地打击、远程侦察等任务中应用广泛<sup>[2]</sup>. 但实际飞行中面临环境高度不确定、重规划

收稿日期: 2026-01-23; 录用日期: 2026-04-28.

基金项目: 国家杰出青年学者项目 (62125303); 国家自然科学基金“叶企孙”科学基金项目 (U2441243); 国家自然科学基金项目 (62573165, 62521005); 黑龙江省自然科学基金项目 (FG2025F001); 教育部基础学科和交叉学科突破计划项目 (JYB2025XDXM206).

†通信作者. E-mail: binzhou@hit.edu.cn.

时效性严苛、轨迹难以满足复杂动力学约束等问题<sup>[3-4]</sup>。故此,如何提升飞行器在新环境下的快速适应能力,实时生成满足避障要求与动力学约束的高质量轨迹,是当前轨迹规划领域的关键难题。

对于轨迹规划问题,国内外学者已开展广泛研究,主要都属于搜索类、采样类与优化类三大范畴<sup>[5]</sup>。如 A\*、D\*等栅格搜索算法及 RRT、PRM 等随机采样算法主要用于低速飞行器的路径寻优<sup>[6]</sup>。然而,对于高速巡航飞行器,其运动学约束较为严格,搜索与采样类方法难以满足高速条件下的可执行性要求<sup>[7]</sup>。

相比之下,优化类方法<sup>[8]</sup>能显式处理各类物理约束,并优化燃油消耗、时间消耗等指标,成为高速飞行器轨迹规划的主流方向。其中,伪谱法<sup>[9]</sup>具有极高求解精度,被广泛用于离线轨迹生成。但其复杂度较高,难以直接用于在线规划<sup>[10]</sup>。为解决实时性问题,序列凸优化方法(SCO)得到广泛关注。SCO通过对非凸约束进行线性化<sup>[11]</sup>,将原问题转化为一组凸子问题迭代求解,能够较好的兼顾效率与性能<sup>[12]</sup>。

对于在线轨迹规划,Li等人<sup>[13]</sup>研究了结合滚动时域控制与SCO的方法,提升了轨迹的平滑性,但在复杂大障碍物环境下易陷入局部极小值。Wang等人<sup>[14]</sup>提出了基于伪谱法的SCO混合策略,在维持凸优化求解效率的基础上提升了轨迹的动力学可行性,但当在线环境与库中样本差异较大时,难以以为SCO提供较优初值。Banerjee等人<sup>[15]</sup>研究了基于神经网络热启动SCO的方法,减少了规划时间,但面对新环境时网络泛化能力受限,预测初值质量下降。

对于以上算法,无论是伪谱法结合SCO,还是神经网络热启动SCO,本质上都较为依赖离线时的环境样本覆盖度<sup>[16]</sup>。当面对新环境时,缺乏自学习、自调整能力,使SCO较难在数次迭代内快速收敛。当新环境与离线测试的环境差距较大时,传统神经网络或几何匹配策略生成的初值往往离最优解流形较远,这导致SCO求解的迭代次数激增<sup>[17]</sup>,严重影响在线重规划的实时性。且修正轨迹为了强行满足几何避障约束,导致控制量出现剧烈跳变或高频震荡,难以满足高速飞行器的平滑控制要求,甚至可能因初值落入不可行域而导致规划失败。

针对上述新环境适应能力不足、规划实时性与动力学平滑性难兼顾问题,本文提出一种基于元学习热启动SCO的在线轨迹重规划方法。核心思想是利用模型无关元学习(MAML)算法的自学习、自适应能力<sup>[18-19]</sup>,快速推断出适于当前环境的较优初值,从而高质量热启动SCO。

本文的主要贡献如下:首先,建立基于球坐标系

下的三自由度高速巡航飞行器动力学模型。并基于hp-自适应伪谱法构建包含丰富避障场景的高质量离线轨迹数据集。其次,融合最近邻残差搭建内外层循环的MAML训练框架,通过学习伪谱法曲线的拓扑特征与动力学特征,输出不同威胁区环境下的最优公共初始参数,为MAML在新环境下快速自适应出特定较优参数提供良好保障。最后,构建基于MAML热启动的SCO在线重规划框架,通过仿真实验验证该方法在面对新威胁区环境时,能够实时生成满足动力学特性的平滑避障轨迹,同时兼顾了规划速度与轨迹物理可行性。

## 1 总体框架与系统建模

### 1.1 总体框架

本文总体框架包含如下四大部分,如图1所示。

### 1.2 飞行器动力学模型

考虑到吸气式高速巡航飞行器特性及任务场景涉及的大范围机动,忽略地球自转,建立基于球坐标系的三自由度飞行器动力学模型<sup>[20]</sup>:

$$\begin{cases} \dot{V} = \frac{T - D}{m} - g \sin \gamma \\ \dot{\gamma} = \frac{L \cos \sigma}{mV} - \frac{g \cos \gamma}{V} + \frac{V \cos \gamma}{r} \\ \dot{\psi} = \frac{L \sin \sigma}{mV \cos \gamma} - \frac{V \cos \gamma \sin \psi \tan \phi}{r} \\ \dot{r} = V \sin \gamma \\ \dot{\delta} = \frac{V \cos \gamma \sin \psi}{r \cos \phi} \\ \dot{\varphi} = \frac{V \cos \gamma \cos \psi}{r} \\ \dot{m} = -\frac{T}{I_{sp} g_0} \end{cases} \quad (1)$$

式中, $V$ 为飞行器速度; $\gamma$ 为航迹角; $\psi$ 为航向角; $r$ 为地心距; $\delta$ 和 $\varphi$ 分别为经度和纬度; $m$ 为飞行器质量,其变化量受推力 $T$ 、发动机比冲 $I_{sp}$ 和海平面重力加速度 $g_0$ 影响; $L$ 和 $D$ 分别为飞行器的升力和阻力; $\sigma$ 为倾侧角。

$$\begin{cases} L = \frac{1}{2} \rho V^2 S C_L \\ D = \frac{1}{2} \rho V^2 S C_D \end{cases} \quad (2)$$

式中, $\rho$ 为大气密度,采用随高度变化的指数近似模型 $\rho(h) = \rho_0 e^{-h/H_s}$ ;  $S$ 为气动参考面积;升力系数 $C_L$ 与阻力系数 $C_D$ 采用文献<sup>[21]</sup>中基于CFD的高保真仿真数据。为了保证求解过程的连续性,本文使用最小二乘法将 $C_D$ 拟合为随 $C_L$ 变化的二次极曲线,公式为 $C_D = 0.4155C_L^2 + 0.0080C_L + 0.0518$ 。

依据高速巡航飞行器特点,本文将状态量设为

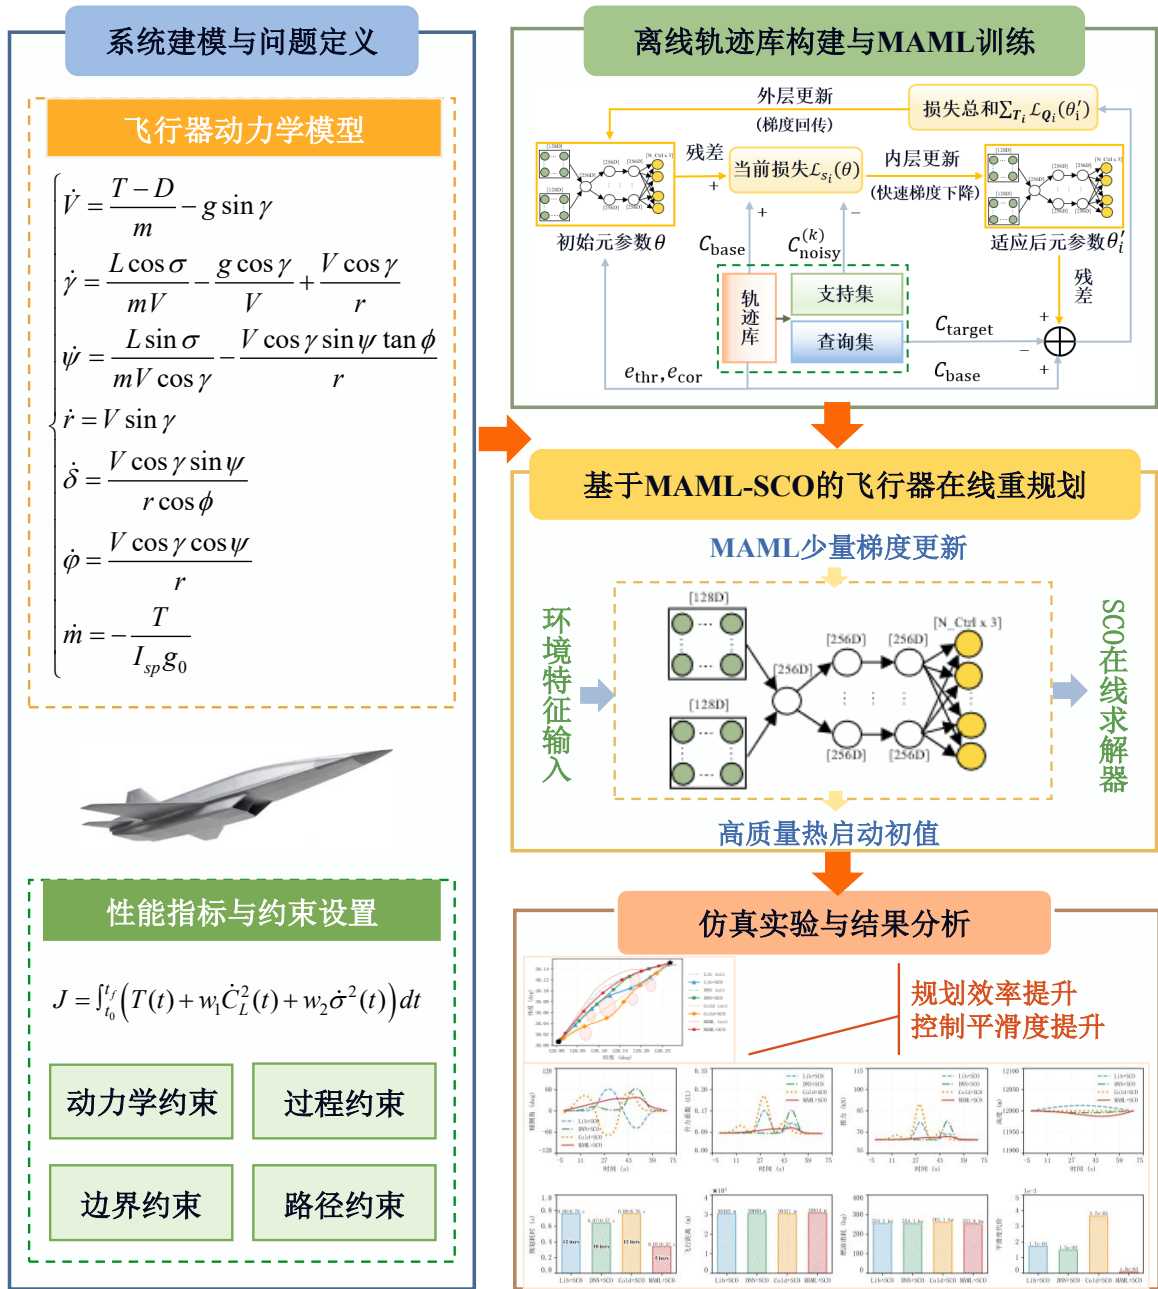


图1 整体框架流程图

$\mathbf{x} = [V, \gamma, \psi, r, \delta, \phi, m]^T$ . 为了确保生成轨迹的平滑性与可跟踪性, 本文使用升力系数  $C_L$  与侧倾角  $\sigma$  的变化量作为控制量, 其中, 使用升力系数而非直接用攻角的原因是为了解耦气动数据从而加快运算速度, 同时使约束更为直观. 最终控制量设为  $\mathbf{u} = [\dot{C}_L, \dot{\sigma}, T]^T$ . 状态量引入气动参数进行状态增广, 修正为  $\mathbf{x} = [V, \gamma, \psi, r, \delta, \phi, m, C_L, \sigma]^T$ .

### 1.3 性能指标与约束设置

对于飞行器的轨迹规划问题, 其本质是一个多约束最优控制问题, 定义如下. 以燃油消耗最小化、控制输入平滑化为目标, 采用 Lagrange 形式建立目标函数如下:

$$J = \int_{t_0}^{t_f} (T(t) + w_1 \dot{C}_L^2(t) + w_2 \dot{\sigma}^2(t)) dt. \quad (3)$$

式中,  $t_0$  与  $t_f$  分别为起始与终止时间;  $T(t)$  为推力, 其积分直接关联燃油消耗;  $w_1$ 、 $w_2$  为权重系数, 为补偿不同物理量的量纲差异并按量级对齐原则分别设为 1000、100, 以匹配高量级推力, 防止过小控制震荡或过大机动受限, 确保生成轨迹的工程可行性.

为保证飞行安全及物理可行性, 需满足以下约束.

#### 1) 动力学约束:

$$\dot{\mathbf{x}} = f(\mathbf{x}(t), \mathbf{u}(t), t). \quad (4)$$

式中,  $f(\cdot)$  为式 (1) 确定的动力学模型.

2) 过程约束:

$$\begin{cases} r_{\min} \leq r(t) \leq r_{\max}, V_{\min} \leq V(t) \leq V_{\max} \\ \gamma_{\min} \leq \gamma(t) \leq \gamma_{\max}, m_{\min} \leq m(t) \leq m_0 \\ C_{L,\min} \leq C_L(t) \leq C_{L,\max}, |\sigma(t)| \leq \sigma_{\max} \\ n_z \leq n_{z,\max}, q \leq q_{\max}, T_{\min} \leq T(t) \leq T_{\max} \\ |\dot{C}_L(t)| \leq \xi_{C_L}, |\dot{\sigma}(t)| \leq \xi_{\sigma} \end{cases} \quad (5)$$

式中,  $n_z$ 为载荷约束;  $q$ 为动压约束; 其余为控制量、状态量约束。

3) 边界约束:

$$\psi_f(\mathbf{x}(t_f), t_f) = \begin{bmatrix} r(t_f) - r(t_0) \\ V(t_f) - V(t_0) \\ \delta(t_f) - \delta_f \\ \varphi(t_f) - \varphi_f \end{bmatrix} = \mathbf{0} \quad (6)$$

式中, 对于终端约束  $\psi_f$ , 设定终端高度、速度与初始值一致, 并约束经纬度。

4) 威胁路径约束:

$$C_{\text{path},j} = \frac{d_j(t)}{R_j} - 1.05 \geq 0. \quad (7)$$

式中, 对于路径约束  $C_{\text{path},j}$ , 引入 5% 的安全余量, 采用局部水平面投影近似。其中,  $d_j(t)$ 为飞行器与威胁中心的欧式投影距离,  $R_j$ 为威胁区  $j$  的半径。

## 2 基于 MAML-SCO 的飞行器在线轨迹重规划

### 2.1 离线轨迹库构建与 MAML 训练

伪谱法的全局最优特性<sup>[22]</sup>为 MAML 训练提供了优质数据。本节基于 hp-自适应伪谱法构建多环境、多约束轨迹库, 利用 B 样条统一数据维度, 融合最近邻残差进行 MAML 训练。因训练轨迹均为动力学可行的伪谱曲线, 残差本质为可行之差, 使生成轨迹兼顾避障与动力学特性, 为 SCO 提供高质量热启动。

#### 2.1.1 基于 hp-自适应伪谱法的离线轨迹库构建

为了构建基于 hp-自适应伪谱法的高速巡航飞行器离线轨迹库, 首先将多约束最优控制问题进行离散化, 之后进行数值求解, 最终建立储存多种威胁区场景下的高质量离线轨迹库数据。具体步骤如下:

1) 离散化

为求解 1.3 节定义的连续最优控制问题, 本文基于 hp-自适应高斯伪谱法, 将无限维微分约束转化为有限维代数约束<sup>[23]</sup>。

step 1: 时域变换:

$$t(\tau) = \frac{t_k - t_{k-1}}{2}\tau + \frac{t_k + t_{k-1}}{2}. \quad (8)$$

式中, 对于第  $k$  个时域区间  $t \in [t_{k-1}, t_k]$ , 引入仿射变换将其映射到  $\tau \in [-1, 1]$ 。

step 2: 全局插值近似:

$$\mathbf{x}^{(k)}(\tau) \approx \sum_{j=1}^{N_k+1} \mathbf{X}_j^{(k)} \mathcal{L}_j(\tau). \quad (9)$$

式中,  $\mathbf{X}_j^{(k)}$ 为离散待求参数;  $\mathcal{L}_j(\tau)$ 为拉格朗日基函数; 状态变量  $\mathbf{x}^{(k)}$ 与控制变量  $\mathbf{u}^{(k)}$ 分别被近似为以  $N_k + 1$ 个插值节点(含端点)与  $N_k$ 个内部配点为节点的拉格朗日插值多项式。

step 3: 动力学方程代数化:

$$\sum_{j=1}^{N_k+1} \mathbf{D}_{ij}^{(k)} \mathbf{X}_j^{(k)} - \frac{t_k - t_{k-1}}{2} \mathbf{f}(\mathbf{X}_i^{(k)}, \mathbf{U}_i^{(k)}) = \mathbf{0}. \quad (10)$$

式中, 通过微分矩阵  $\mathbf{D}^{(k)}$ 将动力学方程转化为代数方程。基于以上离散化步骤, 将连续最优控制问题转化为非线性规划问题。

2) 数值求解

在数值求解方面, 本文基于序列二次规划算法对非线性规划问题进行迭代求解, 并使用稀疏有限差分方法计算 Jacobian 矩阵, 以加速梯度评估。为平衡计算精度与效率, 采用基于误差估计的动态网格策略。若状态误差超过容差, 则依据解的曲率特征选择增加多项式阶数或分割网格区间。

3) 离线轨迹库构建

设置起点与终点, 随机生成 1-4 个不同位置、半径、分布模式下的威胁区。使用伪谱法对不同场景下飞行器进行批量规划, 威胁区绕飞成功且最大约束违背量小于阈值则视为有效样本。提取环境特征向量以及收敛后的最优状态、控制序列, 存入结构化数据库用于后续 MAML 训练。

#### 2.1.2 B 样条参数化与环境特征提取

为有效学习轨迹的空间拓扑与动力学特性, 基于 B 样条法将非均匀采样的高维轨迹数据, 映射到固定维度的特征空间。

1) B 样条曲线拟合

对于离线轨迹库的每条最优轨迹, 提取其三维位置序列  $\mathbf{P}_{\text{raw}} \in \mathbb{R}^{N_{\text{raw}} \times 3}$ , 使用三阶 B 样条基函数进行参数化拟合, 构建最小二乘问题如下:

$$\min_{\mathbf{C}} \|\mathbf{BC} - \mathbf{P}_{\text{raw}}\|_{\text{F}}^2 + \lambda \|\mathbf{LC}\|_{\text{F}}^2. \quad (11)$$

式中,  $\mathbf{B}$ 为 B 样条基矩阵,  $\mathbf{C} \in \mathbb{R}^{N_{\text{cm}} \times 3}$ 为控制点序列,  $\mathbf{L}$ 为正则化拉普拉斯矩阵,  $\lambda$ 为平衡拟合精度与曲线平滑度的权重因子。B 样条控制点不仅压缩了轨迹的几何特征, 其空间分布还隐含了动力学特征, 有利于后续 MAML 训练。

2) 任务环境特征提取

威胁特征向量: 对于每个威胁体, 提取特征向量

$\mathbf{v}_{\text{obs}} = [\bar{x}, \bar{y}, \bar{R}, \delta_{\text{lat}}, p_{\text{type}}]$ . 其中,  $\bar{x}, \bar{y}$ 为威胁区位置,  $\bar{R}$ 为半径长度,  $\delta_{\text{lat}}$ 为威胁中心距走廊轴线的横向偏移量,  $p_{\text{type}}$ 为威胁分布模式.

走廊特征向量: 提取全局任务几何特征, 包含归一化起终点坐标、视线方向矢量、走廊总长及路径曲率统计量.

### 2.1.3 融合最近邻残差的 MAML 训练

为实现对新环境的快速适应, 并使生成轨迹继承离线库的优良动力学特性, 本文基于 B 样条控制点构建融合最近邻残差的 MAML 训练框架, 以加速收敛并保障轨迹可行性, 具体训练参数如表 1 所示.

表1 训练与在线适应配置表

类别	参数名称	参数数值
网络结构 (全连接层)	威胁特征编码	输入-[128, 128]-输出(128)
	走廊特征编码	输入(12)-[128, 128]-输出(128)
	控制点编码	输入(256)-[256, 256]-输出(128 × 3)
离线训练	优化策略	外层学习率0.0001; 内层学习率0.02; Adam优化器;
	开销与收敛	训练耗时0.47 h; 归一化均方误差从0.45下降至0.05左右;
在线适应	在线微调参数	梯度更新30步; 适应学习率0.02
	时空离散参数	网络控制点128个; SCO离散点50个; 飞行时间步长1.3 s;

#### 1) 最近邻基准检索

对于训练阶段, 从离线轨迹库中载入一个环境样本, 并将该环境样本对应的最优轨迹作为目标轨迹. 同时在离线轨迹库中搜寻另一条最相似轨迹作为起始的基准轨迹.

$$j^* = \arg \min_{j \in \mathcal{D}, j \neq i} \|\mathbf{e}_j - \mathbf{e}_{\text{target}}^{(i)}\|_2^2. \quad (12)$$

式中,  $\mathbf{e}_{\text{target}}^{(i)}$ 为当前任务环境特征向量;  $\mathbf{e}_j$ 为离线库中第  $j$  个样本环境特征向量;  $\mathcal{D}$ 为离线库; 依据环境特征检索出最相似环境索引  $j^*$ , 随后提取该环境索引对应的轨迹作为基准轨迹  $\mathbf{C}_{\text{base}}$ .

#### 2) 支持集与查询集构建

为提高泛化能力, 本文采用 K-shot 设置, 基于随机高斯噪声进行数据增强, 从而构建支持集如下:

$$\begin{cases} S_i = \{(\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}}, \mathbf{C}_{\text{noisy}}^{(k)})\}_{k=1}^K \\ \mathbf{C}_{\text{noisy}}^{(k)} = \mathbf{C}_{\text{target}} + \varepsilon, \varepsilon \sim N(0, \sigma_{\text{noise}}^2 \mathbf{I}) \end{cases} \quad (13)$$

式中,  $S_i$ 为支持集;  $\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}}$ 为环境威胁特征与环境走廊特征;  $\mathbf{C}_{\text{noisy}}^{(k)}$ 为  $K$  个加入高斯噪声的目标轨迹. 支持集用于 MAML 训练的内层循环.

查询集则使用未加噪声的真实最优轨迹:

$$Q_i = \{(\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}}, \mathbf{C}_{\text{target}})\} \quad (14)$$

式中,  $Q_i$ 为查询集, 能够评估模型适应后的真实性

能, 用于 MAML 训练的外层循环.

#### 3) 基于残差的双层优化

MAML 基于内层适应与外层更新结构进行训练, 预测输出为目标轨迹为相对于基准轨迹的残差.

前向传播模型:

$$\hat{\mathbf{C}} = \mathbf{C}_{\text{base}} + f_{\theta}(\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}}). \quad (15)$$

式中,  $\hat{\mathbf{C}}$ 为最终预测轨迹,  $f_{\theta}$ 为 MAML 模型, 模型的输出为残差  $\Delta \mathbf{C}$ .

内层循环:

$$\begin{cases} \mathcal{L}_{S_i}(\theta) = \frac{1}{K} \sum_{(\dots, \mathbf{C}_{\text{noisy}}) \in S_i} \|\mathbf{C}_{\text{base}} + f_{\theta}(\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}}) - \mathbf{C}_{\text{noisy}}\|_2^2 \\ \theta'_i = \theta - \alpha \sum_{n=0}^{N-1} \nabla_{\theta'_i} \mathcal{L}_{S_i}(\theta'_i) \end{cases} \quad (16)$$

式中,  $\mathcal{L}_{S_i}(\theta)$ 为基于支持集  $S_i$  计算的损失;  $\theta$ 为公共最初始参数;  $\theta'_i$ 为针对当前任务进行  $N$  步梯度下降后更新的模型参数;  $\alpha$ 为内层学习率.

外层循环:

$$\begin{cases} \mathcal{L}_{Q_i}(\theta'_i) = \|(\mathbf{C}_{\text{base}} + f_{\theta'_i}(\mathbf{e})) - \mathbf{C}_{\text{target}}\|_2^2 \\ \theta \leftarrow \theta - \beta \sum_{T_i} \nabla_{\theta'_i} \mathcal{L}_{Q_i}(\theta'_i) \end{cases} \quad (17)$$

式中,  $\mathcal{L}_{Q_i}(\theta'_i)$ 为基于查询集  $Q_i$  计算的损失;  $\beta$ 为外层学习率; 为加速离线训练效率并降低二阶梯度计算开销, 本文采用一阶近似策略, 利用自适应参数  $\theta'_i$  的一阶梯度之和, 更新公共最优初始参数  $\theta$ .

## 2.2 基于 MAML 热启动的 SCO 在线重规划

SCO 具备高效实时的在线规划特性, 但收敛性能对初始值极为敏感<sup>[24]</sup>. 当任务环境改变时, MAML 的自适应、自学习特性能为 SCO 提供高质量热启动初值, SCO 仅需几步迭代即可生成满足复杂动力学约束与避障要求的飞行轨迹, 实现轨迹的快速在线重规划.

### 2.2.1 MAML 快速自适应

当任务环境变化时, 系统基于当前威胁区分布, 从离线库  $\mathcal{D}$  中检索最相似基准控制点  $\mathbf{C}_{\text{base}}$ , 并将非结构化的环境信息转化为 MAML 可处理的特征向量  $\Phi$ .

对于新环境, 若检索的最相似轨迹被威胁区阻挡, 则启用 MAML 进行快速自适应, 基于当下环境生成调整残差, 为 SCO 提供高质量热启动初值.

#### 1) 自监督物理损失函数:

$$\mathcal{L}_{\text{phy}}(\theta) = \lambda_1 \mathcal{L}_{\text{anc}} + \lambda_2 \mathcal{L}_{\text{obs}} + \lambda_3 \mathcal{L}_{\text{smooth}}. \quad (18)$$

式中, 适应性损失  $\mathcal{L}_{\text{phy}}(\theta)$  为锚点误差  $\mathcal{L}_{\text{anc}}$ 、避障惩罚

$\mathcal{L}_{\text{obs}}$  与平滑项  $\mathcal{L}_{\text{smooth}}$  的加权和.

2) 快速梯度更新:

$$\theta^{(k+1)} = \theta^{(k)} - \alpha \nabla_{\theta} \mathcal{L}_{\text{phy}}(\theta^{(k)}). \quad (19)$$

式中, 执行  $k$  步内层梯度下降, 更新基于特定环境的 MAML 参数  $\theta'$ .

3) 热启动轨迹生成:

$$\tau_{\text{init}} = \mathcal{B}(\mathbf{C}_{\text{base}} + f_{\theta'}(\Phi)). \quad (20)$$

式中,  $\mathcal{B}(\cdot)$  为  $B$  样条基函数映射算子; 基于适应后的参数  $\theta'$  生成最终残差, 合成初始轨迹  $\tau_{\text{init}}$ .

## 2.2.2 SCO 在线求解

原始最优控制问题 (1.3 节) 具有高度非线性与非凸性<sup>[25]</sup>, 难以满足在线规划的实时性要求. 为保障在线规划的实时性, 基于状态空间降阶投影策略<sup>[26]</sup> 构建 SCO, 将高维的状态-控制空间映射到低维的轨迹位置空间, 通过求解一系列凸子问题快速规划轨迹, 并通过动力学逆解验证物理可行性.

1) 凸化目标函数:

$$\begin{aligned} \min_{\mathbf{P}, \epsilon} J = & \lambda_1 \sum_{i=0}^{N-1} \|\Delta \mathbf{p}_i\|_2 + \\ & \sum_{m=2}^3 \lambda_m \sum_{i=0}^{N-m} \|\Delta^m \mathbf{p}_i\|_2^2 + \\ & \eta \|\mathbf{P} - \mathbf{P}^{(k)}\|_F^2 + \mu \|\epsilon\|_1. \end{aligned} \quad (21)$$

式中,  $\mathbf{P} \in \mathbb{R}^{N \times 3}$  为轨迹点矩阵;  $\Delta^m \mathbf{p}_i$  表示  $m$  阶差分向量;  $\mathbf{P}^{(k)}$  为上一轮 (第  $k$  次) 迭代解;  $\epsilon$  为避障松弛变量; 燃油消耗代理由第一项巡航长度项、第二项  $m=2$  的加速度平滑项组成; 控制可行性代理为第二项  $m=3$  的加加速度平滑项;  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  按阶数递增原则分别选取为 2、200、500, 以补偿差分衰减, 防止动力学剧烈突变;  $\eta$  为信赖域权重随迭代次数衰减;  $\mu$  为避障松弛权重设为 20000.

2) 凸化约束:

$$\begin{cases} \mathbf{p}_0 = \mathbf{p}_{\text{start}}, \quad \mathbf{p}_N = \mathbf{p}_{\text{end}} \\ \|\Delta^2 \mathbf{p}_i\|_2 \leq a_{\text{max}} \cdot \Delta t^2 \\ \mathbf{e}_3^T \mathbf{p}_i \geq H_{\text{min}}(q_{\text{max}}) \\ \mathbf{n}_{i,j}^T (\mathbf{p}_i - \mathbf{p}_{o,j}) \geq R_j - \epsilon_{i,j} \\ \epsilon_{i,j} \geq 0 \end{cases} \quad (22)$$

式中, 第一项为线性边界; 第二项为过载二阶锥约束; 第三项为动压线性约束; 第四项为避障半平面约束; 第五项为非负松弛.

对于上述凸化约束, 速度与法向加速度基于巡航速率与位置序列的离散差分进行估计. 动压因速率恒定仅受密度影响, 基于飞行高度进行等效估计. 威胁约束经一阶泰勒展开凸化, 通过威胁中心与上

轮轨迹点连线计算法向量  $\mathbf{n}_{i,j}$ , 通过 5% 半径膨胀及信赖域保证收敛与安全裕度.

3) 迭代与收敛:

$$\|\mathbf{P}^{(k+1)} - \mathbf{P}^{(k)}\| \leq \epsilon_{\text{tol}}. \quad (23)$$

式中,  $\mathbf{P}^{(k+1)}$  为新一轮轨迹, 基于内点法求解上述凸子问题得到, 重复迭代直至满足上式收敛条件.

基于 MAML-SCO 的在线轨迹重规划算法整体伪代码框架如表 2 所示.

表2 基于 MAML-SCO 的在线轨迹重规划算法伪代码

步骤	算法流程描述
输入	<b>离线:</b> 离线轨迹库 $\mathcal{D}$ , 初始参数 $\theta$ , 内外环学习率 $\alpha, \beta$ <b>在线:</b> 元模型 $\theta_{\text{meta}}$ , 环境 $\mathbf{e}_{\text{cor}}, \mathbf{e}_{\text{thr}}$ , 收敛与安全阈值 $\epsilon_{\text{tol}}, \epsilon_{\text{safe}}$
阶段1	<b>离线MAML元训练</b>
1	从 $\mathcal{D}$ 中采样元任务批次, 构建支持集 $S_i$ 与查询集 $Q_i$
2	<b>内层更新:</b> $\theta'_i = \theta - \alpha \sum_{n=0}^{N-1} \nabla_{\theta'_i} \mathcal{L}_{S_i}(\theta'_i)$
3	<b>外层更新:</b> $\theta \leftarrow \theta - \beta \sum_{i=1} \nabla_{\theta} \mathcal{L}_{Q_i}(\theta'_i)$
4	循环收敛后, 保存元先验模型 $\theta_{\text{meta}} \leftarrow \theta$
阶段2	<b>在线自适应与序列凸优化重规划</b>
5	初始化自适应网络参数 $\theta_{\text{adapt}} \leftarrow \theta_{\text{meta}}$
6	<b>for</b> $step = 1$ <b>to</b> $N_{\text{adapt}}$ <b>do</b>
7	前向输出控制点 $\mathbf{U} = f_{\theta_{\text{adapt}}}(\mathbf{e}_{\text{thr}}, \mathbf{e}_{\text{cor}})$
8	梯度下降更新: $\theta_{\text{adapt}} \leftarrow \theta_{\text{adapt}} - \alpha \nabla_{\theta_{\text{adapt}}} \mathcal{L}_{\text{phy}}(\mathbf{U})$
9	<b>end for</b>
10	热启动轨迹生成 $\tau_{\text{init}}$ , 并采样为离散点 $\mathbf{P}_{\text{init}}$
11	— 安全机制1: 防初值发散兜底 —
12	<b>if</b> $\mathbf{P}_{\text{init}}$ 严重违背动力学包络 <b>或</b> 导致求解器发散 <b>then</b>
13	$\mathbf{P}_{\text{init}} \leftarrow \mathbf{P}_{\text{baseline}}$ (降级调用离线库轨迹作为初值)
14	<b>end if</b>
15	执行序列凸优化求解: $\mathbf{P}^*, \epsilon^* \leftarrow \text{SCO\_Solver}(\mathbf{P}_{\text{init}})$
16	— 安全机制2: 防软约束物理穿透兜底 —
17	<b>if</b> 最大避障松弛变量 $\ \epsilon^*\ _{\infty} > \epsilon_{\text{safe}}$ <b>then</b>
18	指数级增大松弛惩罚权重, 触发二次硬约束求解
19	<b>if</b> 极值工况下仍无可行解 <b>then</b> 紧急避让机动指令
20	<b>end if</b>
21	<b>return</b> 最终重规划轨迹 $\mathbf{P}^*$

## 3 实验与结果分析

本文选用高速巡航飞行器作为轨迹规划的研究对象, 设定不同威胁区环境下的仿真实验. 算法运行的计算机 GPU 型号为 NVIDIA GeForce RTX 4070.

设置初始高度为 12 km, 速度为 450 m/s, 终端高度、速度与初始值一致. 过载限制为  $\leq 6G$ ; 动压限制为  $\leq 35\text{kPa}$ ; 推力限制为  $[0, 120]$  kN; 倾侧角限制为  $[-80, 80]$  度; 升力系数限制为  $[0, 0.8]$ ; 测试在新环境下飞行器的在线重规划能力.

图2为新环境下飞行器的在线重规划对比图。蓝色虚线为离线伪谱法轨迹库 Lib 检索的当前环境最相似轨迹, 带有三角标记的蓝色实线为经 SCO 调整后的最终轨迹; 绿色点划线为深度神经网络 DNN 输出的初始轨迹, 带有方块标记的绿色实线为相应的 SCO 最终轨迹; 橙色点线为冷启动 Cold 下的初始轨迹, 带有十字标记的橙色实线为对应的 SCO 最终轨迹; 红色实线则为 MAML 针对当前环境自适应生成的初始轨迹, 带有圆点标记的红色实线为 SCO 调整后的最终轨迹。

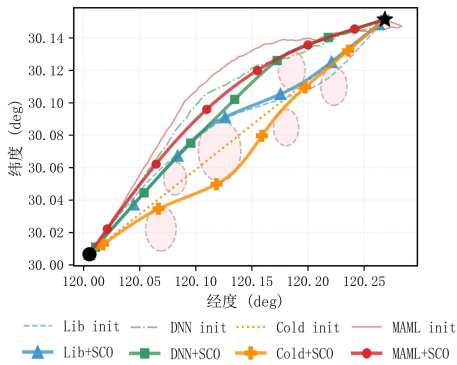


图2 威胁区避障轨迹对比图

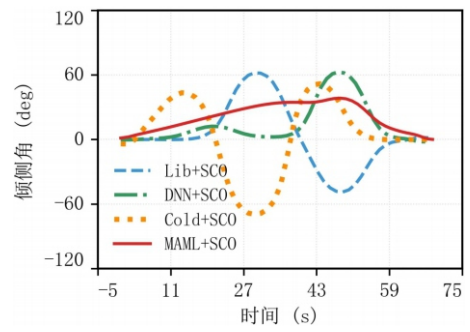
对于 DNN 与 MAML, 实验中采用相同的网络拓扑结构与参数规模, 区别为 MAML 引入了内外环元优化, 而 DNN 沿用标准梯度下降机制。二者在离线阶段基于同一特征库、数据集及损失函数拟合收敛, 在线阶段执行相同步数进行少量更新, 以保证基线对比的公平性。

对比各类算法可知, MAML 生成的初始轨迹能更敏锐地捕捉当前环境特征, 其拓扑结构有效避开了威胁区; 经过 SCO 微调后, 生成一条平滑切过威胁区边缘的轨迹。

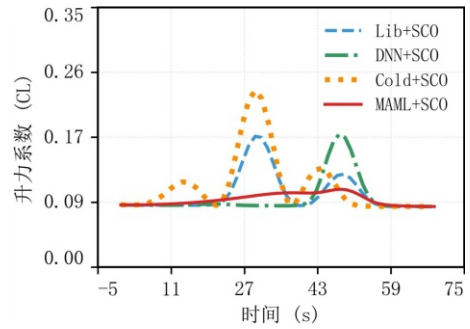
图3为飞行器的控制量、高度变化曲线。相比于 Lib+SCO、DNN+SCO 与 Cold+SCO, 基于 MAML 热启动的 MAML+SCO 控制曲线更为平缓。这是由于 MAML 在训练过程中学习到伪谱法的优异轨迹特征, 且在面对新环境时具有自主学习、自适应能力, 能够生成天然具备避障与动力学优异性的初始轨迹, 便于 SCO 进行进一步优化。

图4为四个算法的具体性能对比图。相比其他三种方法初始化的 SCO, 基于 MAML 热启动的 SCO 性能更为优越, 在保持飞行距离、燃油消耗相似的情况下, 规划耗时、控制平滑损失大幅度减小。


为了验证算法的普适性, 本文进一步测试了20个具有梯度难度的不同新环境。相比于离线库样本(1-4个), 该测试工况设置了如屏障式阻断、收敛



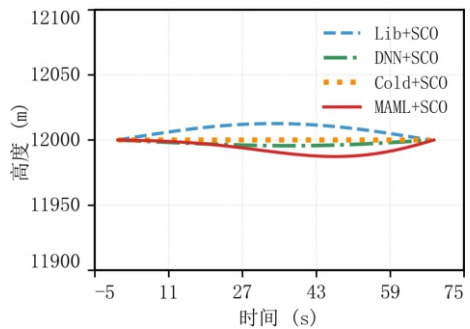
(a) 倾侧角变化曲线



(b) 升力系数变化曲线



(c) 推力变化曲线




(d) 高度变化曲线


图3 控制量与高度曲线变化图

通道等更为苛刻的威胁区拓扑排布, 并具体包含两个层级的改变: 一是威胁数量在离线库范围内, 但尺寸与位置不同的小跨度改变; 二是威胁总数(扩展至5-6个)与空间分布密度均显著超出离线库样本范围的大跨度改变。算法的平均性能如下:


表3与图5所示, 对于20个不同的新环境, MAML+SCO 算法的平均规划耗时仅为0.36 s, 具体为 MAML 在线适应平均时间0.07 s, 后续 SCO 规划平均时间0.29 s, 控制量的平均平滑度代价损失为




(a) 规划耗时对比



(b) 飞行距离对比



(c) 燃油消耗对比



(d) 平滑度代价对比


图4 具体性能对比图

表3 多场景下平均性能对比


算法类型	规划耗时 (s)	飞行距离 (m)	燃油消耗 (kg)	平滑度代价
Lib+SCO	0.00+0.88	30949	270	0.007
DNN+SCO	0.07+0.71	31109	264	0.003
ColdStart+SCO	0.00+1.85	29732	262	0.003
MAML+SCO	0.07+0.29	30551	260	0.001

0.001. 分析其他对比基线, 相比于平均耗时高达 1.85 s 的 Cold+SCO, Lib+SCO 的平均规划耗时为 0.88 s, 已是目前快速在线规划的常用方法.


DNN+SCO 通过引入监督学习技术, 在 Lib+SCO




(a) 规划耗时箱型图



(b) 控制平滑度代价箱型图



(c) 平均规划耗时对比



(d) 平均控制平滑度代价对比

图5 多环境下性能对比图

基础上, 平均耗时缩短了 11.5%, 平均平滑度代价降低了 52.8%, 是目前基于学习的在线规划前沿方向.

然而, 无论是 Lib+SCO 还是 DNN+SCO 算法, 都较为依赖离线环境样本的覆盖度. 当新环境与离线库中样本差异过大时, 初始轨迹质量将下降. 本文引入新环境下具有自学习、自适应能力的 MAML 元学习机制, 在 Lib+SCO 基础上, 平均耗时缩短了 59.2%, 平均平滑度代价降低了 83.1%. 与目前前沿的 DNN+SCO 算法相比, 本方法在计算实时性与控制轨迹平滑度上实现了进一步的性能提升.

通过定性与定量分析, 充分证明了 MAML+SCO

在线重规划算法的优越性. 面对新环境时, 能够更快的规划出控制量更平滑、更符合动力学特性的避障曲线.

## 4 结论

本文针对新环境下飞行器的在线重规划问题, 提出一种基于 MAML-SCO 的在线轨迹重规划方法. 首先基于 hp-自适应伪谱法构建了包含丰富避障机理的离线最优轨迹库; 其次, 设计了融合最近邻残差机制的 MAML 内外层训练模型, 通过挖掘离线轨迹库中的动力学流形与拓扑特征, 获取了具备强泛化能力的元初始化参数; 最后, 建立了 MAML 热启动 SCO 的在线重规划框架, 利用 MAML 网络的快速推理能力, 为 SCO 提供高质量初值, 降低求解的迭代难度. 经仿真验证, 与传统的库检索热启动 Lib+SCO 及前沿的监督学习热启动 DNN+SCO 相比, 本方法在面对未知新环境时展现出了更显著的优势, 在满足几何避障约束与动力学可行性基础上, 实现了计算效率与控制平滑性的双重提升.

## 参考文献 (References)

- [1] Luo S B, Sun Y H, Liu J, et al. Research status and development trend of air-breathing high-speed vehicle/engine integration[J]. *Aerospace Science and Technology*, 2024, 155: 109675.
- [2] Pollock L, Wild G. An examination of high-speed aircraft — Part 1: Past, Present, and Future[J]. *Transportation Engineering*, 2024, 18: 100290.
- [3] Lim W X, Zhong Z W. Re-planning of flight routes avoiding convective weather and the “three areas” [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(3): 868-877.
- [4] 刘洋, 吴昊天, 王林晟, 等. 基于神经动力学优化的无人系统研究综述[J]. *控制与决策*, 2025, 40(7): 2049-2069.  
(Liu Y, Wu H T, Wang L S, et al. A review of unmanned systems research based on neurodynamic optimization[J]. *Control and Decision*, 2025, 40(7): 2049-2069.)
- [5] Sheltami T, Ahmed G, Ghaleb M, et al. UAV path planning and trajectory optimization: A comprehensive survey[J]. *Arabian Journal for Science and Engineering*, DOI: 10.1007/s13369-025-10971-8.
- [6] Karaman S, Frazzoli E. Sampling-based algorithms for optimal motion planning[J]. *The International Journal of Robotics Research*, 2011, 30(7): 846-894.
- [7] Betts J T. Survey of numerical methods for trajectory optimization[J]. *Journal of Guidance, Control, and Dynamics*, 1998, 21(2): 193-207.
- [8] 文郁, 黄江帅, 江涛, 等. 安全平滑的改进时间弹性带轨迹规划算法[J]. *控制与决策*, 2022, 37(8): 2008-2016.  
(Wen Y, Huang J S, Jiang T, et al. Safe and smooth improved time elastic band trajectory planning algorithm[J]. *Control and Decision*, 2022, 37(8): 2008-2016.)
- [9] Patterson M A, Rao A V. GPOPS-II: A MATLAB software for solving multiple-phase optimal control problems using hp-adaptive Gaussian quadrature collocation methods and sparse nonlinear programming[J]. *ACM Transactions on Mathematical Software*, 2014, 41(1): 1-37.
- [10] Zhang H N, Zhang W D, Ma Z W, et al. On-line trajectory reconstruction based on customized pseudo-spectrum and sequential convexification under nonfatal failure of launch vehicle upper stage[C]. *IEEE International Conference on Unmanned Systems*. Guangzhou, 2022: 1167-1172.
- [11] Mao Y Q, Dueri D, Szmuk M, et al. Successive convexification of non-convex optimal control problems with state constraints[J]. *IFAC-PapersOnLine*, 2017, 50(1): 4063-4069.
- [12] Liu X F, Lu P. Solving nonconvex optimal control problems by convex optimization[J]. *Journal of Guidance, Control, and Dynamics*, 2014, 37(3): 750-765.
- [13] Li K, Guo Y N, Ran G T, et al. Convex optimization-based model predictive control for Mars ascent vehicle guidance system[J]. *IEEE/CAA Journal of Automatica Sinica*, 2025, 12(10): 2159-2161.
- [14] Wang J B, Cui N G, Wei C Z. Rapid trajectory optimization for hypersonic entry using convex optimization and pseudospectral method[J]. *Aircraft Engineering and Aerospace Technology*, 2019, 91(4): 669-679.
- [15] Banerjee S, Lew T, Bonalli R, et al. Learning-based warm-starting for fast sequential convex programming and trajectory optimization[C]. *IEEE Aerospace Conference*. Big Sky, 2020: 1-8.
- [16] Yan S N, Tao G H, Liu X W, et al. Correlations between deep neural network model coverage criteria and model quality[C]. *Proceedings of the 28th ACM Joint Meeting on European Software Engineering Conference and Symposium on the Foundations of Software Engineering*. New York, 2020: 775-787.
- [17] Szmuk M, Acikmese B. Successive convexification for 6-DoF Mars rocket powered landing with free-final-time[C]. *AIAA Guidance, Navigation, and Control Conference*. Kissimmee, 2018: AIAA2018-0617.
- [18] Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks[C]. *Proceedings of the 34th International Conference on Machine Learning*. Sydney, 2017: 1126-1135.
- [19] 李歆, 李显, 李帅, 等. 小样本下基于元学习和网络结构搜索的新模态故障诊断[J]. *控制与决策*, 2023, 38(11): 3175-3183.  
(Li X, Li X, Li S, et al. Fault diagnosis based on meta learning and neural architecture search for new modes with small samples[J]. *Control and Decision*, 2023,

- 38(11): 3175-3183.)
- [20] 王奕涵, 柳青, 朱柏羊, 等. 弱初始条件依赖的高速巡航飞行器轨迹规划[J]. *战术导弹技术*, 2025(3): 95-105.  
(Wang Y H, Liu Q, Zhu B Y, et al. Trajectory planning of high-speed cruise aircraft with weak initial condition dependence[J]. *Tactical Missile Technology*, 2025(3): 95-105.)
- [21] Dai P, Yan B B, Huang W, et al. Design and aerodynamic performance analysis of a variable-sweep-wing morphing waverider[J]. *Aerospace Science and Technology*, 2020, 98: 105703.
- [22] Rao A V. A survey of numerical methods for optimal control[J]. *Advances in the Astronautical Sciences*, 2009, 135(1): 497-528.
- [23] Darby C L, Hager W W, Rao A V. An hp-adaptive pseudospectral method for solving optimal control problems[J]. *Optimal Control Applications and Methods*, 2011, 32(4): 476-502.
- [24] Wang Z B, Lu Y. Improved sequential convex programming algorithms for entry trajectory optimization[J]. *Journal of Spacecraft and Rockets*, 2020, 57(6): 1373-1386.
- [25] Malyuta D, Reynolds T P, Szmuk M, et al. Convex optimization for trajectory generation: A tutorial on generating dynamically feasible trajectories reliably and efficiently[J]. *IEEE Control Systems*, 2022, 42(5): 40-113.
- [26] Mellinger D, Kumar V. Minimum snap trajectory generation and control for quadrotors[C]. *IEEE International Conference on Robotics and Automation*. Shanghai, 2011: 2520-2525.

### 作者简介

李佳仪 (2002-), 女, 硕士生, 主要研究方向为飞行器轨迹规划与决策, E-mail: [lgy13510913127@163.com](mailto:lgy13510913127@163.com);

周彬 (1981-), 男, 教授, 博士, 博士生导师, 主要研究方向为控制理论和飞行器制导与控制, E-mail: [binzhou@hit.edu.cn](mailto:binzhou@hit.edu.cn);

付艳明 (1978-), 男, 副教授, 博士, 主要研究方向为鲁棒控制理论、航天器控制, E-mail: [fuyanming@hit.edu.cn](mailto:fuyanming@hit.edu.cn).