

面向大型变型航天器的智能轨道预报方法*

廖嘉豪, 孟云鹤

中山大学人工智能学院, 广东 珠海 519082

摘要: 低轨大型航天器的中长期轨道预报精度主要受空间环境不确定性及在轨构型变化的影响。传统预报方法受限于大气密度模型误差及阻力系数的适用性, 且对迎风面积随构型变化缺乏精细建模。本文提出了一种面向大型变型航天器的中长期智能轨道预报方法。该方法引入伪阻力系数概念, 将大气密度和阻力系数的不确定性统一建模为可学习的时变参数, 构建了融合高精度动力学模型与数据驱动的预报框架; 进一步给出了伪阻力系数修正模型, 显式刻画迎风面积变化与伪阻力系数之间的定量关系。以某在轨大型变型航天器为研究对象的仿真实验表明: 在多次变型场景下, 所提方法的轨道预报误差显著低于传统方法, 可有效提升中长期预报的精度与适应性。

关键词: 大型航天器; 轨道预报; 阻力系数; 迎风面积

中图分类号: V412.4 **文献标志码:** A **文章编号:** 2097-0137(2026)03-0128-07

Intelligent orbit prediction for large morphing spacecraft

LIAO Jiahao, MENG Yunhe

School of Artificial Intelligence, Sun Yat-sen University, Zhuhai 519082, China

Abstract: The accuracy of medium and long-term orbit predictions for LEO spacecraft is susceptible to uncertainties in the space environment and on-orbit configuration changes. The traditional prediction methods are limited by errors in atmospheric density models, the inadequate applicability of drag coefficients, and the lack of detailed modeling of the variation in effective windward area due to configuration changes. This paper proposes a medium and long-term orbit prediction method for large morphing spacecraft. This method introduces pseudo-drag coefficient to uniformly model the multiple uncertainties related to atmospheric drag as a learnable time-varying parameter. It constructs a prediction framework that integrates high-precision dynamic orbit model with data-driven techniques. Furthermore, a correction model for the pseudo-drag coefficient is established to explicitly characterize the quantitative relationship between changes in the windward area and the pseudo-drag coefficient. Simulation experiments conducted on a large morphing spacecraft demonstrate that, under multiple morphing scenarios, the proposed method achieves significantly lower orbit prediction errors than traditional method, effectively enhancing the accuracy and adaptability of medium and long-term prediction.

Key words: large spacecraft; orbit prediction; drag coefficient; windward area

低地球轨道(LEO)空间环境正以前所未有的速度趋于拥挤。截至 2024 年, 全球编目的空间物体已

超过 47 000 个, 月均记录的接近事件近万起 (NORAD, 2024; NASA, 2025)。大型航天器由于

* 收稿日期: 2026-01-02

录用日期: 2026-01-27

网络首发日期: 2026-04-07

基金项目: 中山大学智控实验室开放基金(ICL-2023-0403)

作者简介: 廖嘉豪(2000年生), 男; 研究方向: 空天智能; E-mail: liaojh28@mail2.sysu.edu.cn

通信作者: 孟云鹤(1978年生), 男; 研究方向: 空天智能; E-mail: mengyh7@mail.sysu.edu.cn

全文阅读



ZR20260013

物理尺寸大、横截面积广,面临着越来越高的碰撞风险。因此,高精度、高可靠性的轨道预报不仅是保障大型航天器在轨安全的核心需求,也是维护LEO空间可持续使用的关键技术。

传统的轨道预报通常采用“轨道确定—轨道预报”的两阶段模式:先利用观测数据估计初始状态与动力学参数,再通过数值积分进行预报。其中,大气阻力是影响低轨航天器轨道预报精度的最主要摄动力,其建模精度高度依赖于大气密度模型(如NRLMSISE-00)及空间环境指数(F10.7、 A_p 等)的预报准确性(Emmert, 2015)。然而,这些环境参数的中长期预测仍存在显著不确定性;同时,传统方法通常将定轨阶段计算的阻力系数沿用于预报期间。这样会难以适应空间环境的动态变化,导致中长期预报误差快速累积。

智能轨道预报方法近年来受到广泛关注。当前研究主要沿两条路径展开:其一是基于历史误差建模的数据驱动补偿方法,通过机器学习模型(如高斯过程、支持向量机、神经网络等)直接学习传统力学模型预报误差的规律并进行补偿(Peng et al., 2023; Li et al., 2021; Huang et al., 2024; Lin et al., 2025);其二是基于大气密度建模改进方法,利用机器学习技术直接校正密度模型输出或预测关键空间环境参数(Calabia et al., 2021; Hao et al., 2024; Chen et al., 2025; Cimmino et al., 2023)。这些方法在提升轨道预报精度方面取得了显著进展。

随着在轨任务复杂度的不断提升,特别是大型航天器在运行中频繁经历帆板转动或构型变化等调整,其迎风面积可能在短时间内发生显著变化。此特性对轨道预报提出了新的需求与挑战。轨道预报不仅需兼顾中长期时间尺度,还需合理反映几何状态动态演化对大气阻力的影响。当前,针对大型航天器的智能轨道预报,主要集中于两类场景:一类是面向短期精密定轨,结合高精度观测与详细构型信息精细刻画气动特性(雷骥玮等, 2023; Montenbruck et al., 2011);另一类是面向长期轨道的演化分析(徐玲玲等, 2024; 段成林等, 2025)。具备应对构型变化场景的智能轨道预报方法,成为了一个值得探索的新方向。

在已有的研究基础上,本文提出了一种面向大型变型航天器的智能轨道预报方法。首先引入伪阻力系数,将复杂的大气阻尼建模问题转化为对该参数的预测问题;然后构建一个物理约束明晰、数据适应性强的智能轨道预报框架;进一步提出面向

大型变型航天器的伪阻力系数修正模型,并将之集成到智能轨道预报框架中;最后以某在轨大型变型航天器为对象开展仿真实验,验证方法的适用性与有效性。

1 基于伪阻力系数的轨道预报框架

为了克服传统方法难以有效表征大气阻力不确定性的局限,提出了伪阻力系数,并将大气密度和阻力系数统一建模为可学习的时变参数。在此基础上,构建融合高精度轨道动力学模型与数据驱动机制的智能预报架构。

1.1 轨道动力学模型

在地心惯性坐标系中,卫星轨道动力学方程为

$$\begin{cases} \ddot{\vec{r}} = -\mu \frac{\vec{r}}{r^3} + \vec{a}_p, \\ \vec{a}_p = \vec{a}_{\text{harmonic}} + \vec{a}_{\text{three-body}} + \vec{a}_{\text{drag}} + \vec{a}_{\text{SRP}} + \vec{a}_{\text{other}}, \end{cases}$$

其中 \vec{r} 为卫星位置向量; μ 为地球引力常数; \vec{a}_p 为摄动加速度,包括非球形引力、第三体引力、大气阻力、太阳光压以及其他摄动。在LEO轨道预报中,大气阻力 \vec{a}_{drag} 是主要的非保守力,其表达式为

$$\vec{a}_{\text{drag}} = -\frac{1}{2} \left(\frac{A}{m} \right) C_D \rho \vec{v}_e,$$

式中 A 表示迎风面积, m 是卫星质量, C_D 为阻力系数, ρ 为大气密度, \vec{v}_e 为卫星相对于大气的速度。

1.2 伪阻力系数

传统轨道预报方法在计算大气阻力加速度 \vec{a}_{drag} 时,通常采用分步解耦建模策略:首先基于大气密度模型,结合空间环境参数(如太阳活动指数F10.7、地磁活动指数 A_p)的预报值,估算未来时段的大气密度 ρ ;同时,在轨道确定阶段估算阻力系数 C_D ,并假设其在预报时段内保持恒定。这种策略在短期轨道预报或空间环境相对平稳时具有工程实用性。然而,在中长期预报任务或动态变化的空间环境,其局限性逐渐凸显。比如,预报阶段的 ρ 依赖于空间环境参数的预测,而这些参数的长期预测目前存在较大的不确定性。这种不确定性与模型自身的结构误差叠加,会导致 ρ 的估计精度显著下降。此外,阻力系数 C_D 作为定轨阶段的最优估计,其值吸收了大气密度模型、航天器面质比等误差,与大气密度模型形成一个自治系统(汪宏波等, 2016)。因此,预报阶段 C_D 的适用性就会面临挑战;尤其是在中长期预报中,其准确性会大幅降低。

针对上述局限性,本文引入伪阻力系数(记为 \tilde{C}_D)的概念。其核心思想是:在采用固定空间环境

参数计算大气密度的前提下,将真实空间环境对大气密度的时变影响,作为乘性因子综合至伪阻力系数中。首先假设空间环境参数保持恒定,此时对应的基准大气密度记为 ρ^* ;然后,通过最小化轨道预报残差反演得到阻力系数(即伪阻力系数),从而将真实空间环境的扰动融入至阻力系数中,此时的阻力系数不再需要定轨求解,同时也失去了原本的物理意义。鉴于此,卫星受到的大气阻力加速度可以重新表示为

$$\vec{a}_{\text{drag}} = -\frac{1}{2} \left(\frac{A}{m} \right) \rho^* \bar{C}_D v_e \vec{v}_e, \quad (1)$$

式中的 ρ^* 是一个基于固定空间环境参数的、无需预测的已知量,因此关于轨道预报的精度问题可转化为对 \bar{C}_D 的精确预测。

1.3 基于伪阻力系数的轨道预报流程

基于伪阻力系数的概念,构建了如图1所示的智能轨道预报框架。该框架将物理模型与数据驱动方法深度融合,包含3个步骤:

第1步,伪阻力系数数据集构建。该阶段旨在生成高质量的监督学习数据集,是后续机器学习的

基础。给定预报起始时刻 T_0 和预报时长 N (单位:天),利用从历史时刻 T_{-M} 到 T_0 (其中 $M \gg N$)的精密星历数据,结合高精度轨道动力学模型(其中空间环境参数设置为固定值),逐日计算出对应的伪阻力系数序列 $\{\bar{C}_D(T_{-M}), \bar{C}_D(T_{-M+1}), \dots, \bar{C}_D(T_{-N})\}$ 。

第2步,伪阻力系数的智能学习和预测。该阶段是框架的智能核心,旨在利用第1阶段数据集,让模型学习从输入特征(如历史伪阻力系数序列和空间环境参数)到目标变量 \bar{C}_D 的映射关系,实现对未来值的精准预测。本质上,这是一个时间序列预测问题,可采用多种方法实现,包括传统模型(如ARIMA)、机器学习方法(如XGBoost,SVR)以及深度学习模型(如RNN,LSTM)。

第3步,轨道数值积分与预报。该阶段是框架的最终输出。将第2步得到的 $\bar{C}_D(T_0)$ 带入公式(1),并利用与第1步一致的高精度轨道动力学模型,以 T_0 时刻的精确轨道状态为初始条件,采用数值积分方法进行轨道外推,最终生成 N 天的轨道预报结果。

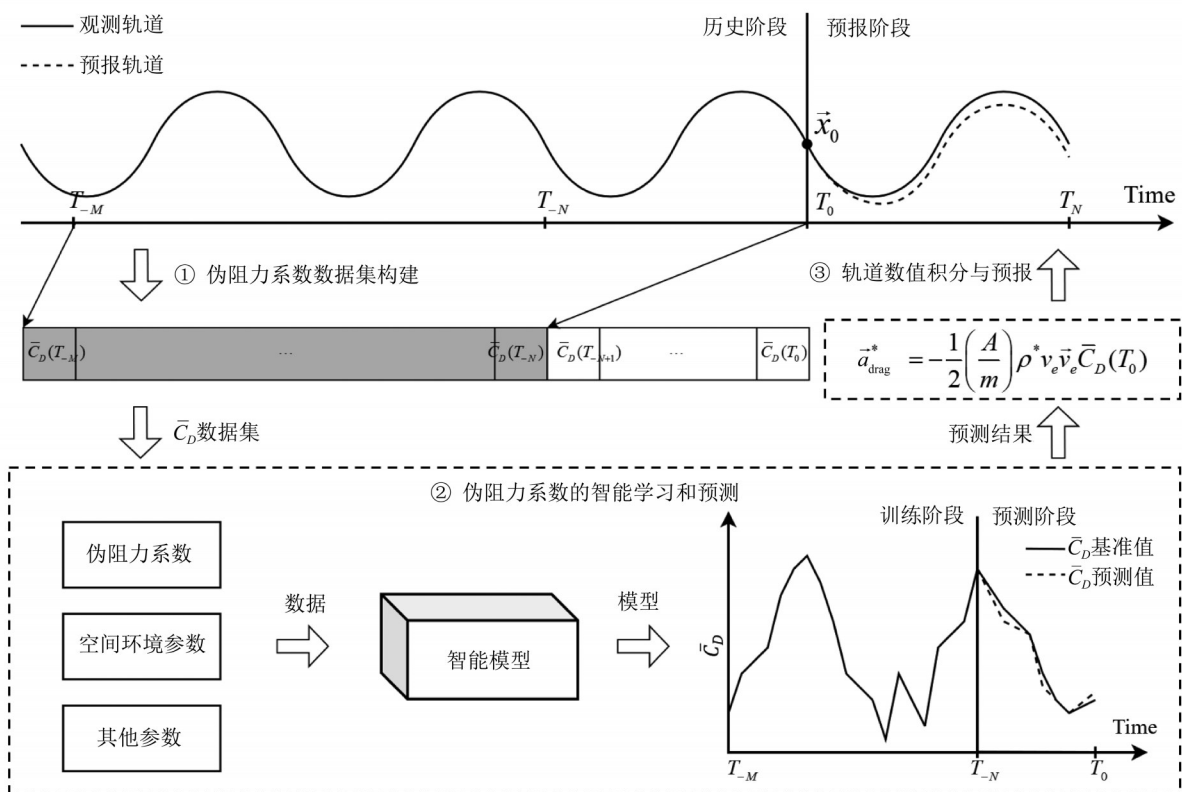


图1 基于伪阻力系数的轨道预报流程图

Fig. 1 Flowchart of orbit prediction based on pseudo-drag coefficient

2 考虑变型情况的伪阻力系数修正模型

大型变型航天器构型变化多样,在轨道动力学层面,最显著的影响集中体现为有效迎风面积的改变。当航天器因任务需要进行构型变换时,其轨道位置呈连续变化,但有效迎风面积 A 却可能发生剧烈变化,若忽略其物理机制,仅将 \bar{C}_D 视为黑箱时间序列进行处理,则难以建立其与空间环境参数之间的有效映射关系。尤其在迎风面积发生显著变化时,会导致轨道预报精度急剧下降。因此,需要建立一种能够显式刻画迎风面积变化影响的伪阻力系数修正模型,提升对大型变型航天器的轨道预报的能力。

2.1 大型航天器变型对轨道预报的影响

大型航天器的构型变化会显著改变其气动外形,其中直接影响轨道阻力的是有效迎风面积 A 。由公式(1)可知,在小型航天器场景下,航天器变型引起的迎风面积波动通常较小,其对 \bar{C}_D 的影响往往可以忽略。然而,对于大型航天器,迎风面积变化会从以下方面对轨道预报精度产生显著影响:

(1)动力学适用性问题。如图2所示,实线表示迎风面积保持为 A_1 的条件下航天器的真实轨道演化。假设某时段航天器执行构型调整,迎风面积由 A_1 变为 A_2 ,且迎风面积变化幅度不可忽略,其真实轨道将按虚线所示路径演化。若轨道预报仍沿用与 A_1 匹配的伪阻力系数 \bar{C}_{D1} ,则动力学模型无法准确反映当前气动特性,形成图中阴影区域所示的显著预报误差。

(2)数据异质性问题。在构建伪阻力系数数据集时,若各样本对应的有效迎风面积不一致,则不同面积条件下的 \bar{C}_D 本质上是物理含义不同的“异源数据”。若直接将其输入机器学习模型进行统一训练,将显著干扰特征提取与规律学习过程,削弱模型的泛化能力,最终导致预测性能下降。




图2 迎风面积变化引起的轨道预报偏差

Fig. 2 Orbit prediction error caused by windward area variation

值得注意的是,当前大型航天器的大面积变化通常源于预先规划的任务动作,其发生时刻、构型调整方式及持续时间在任务规划阶段即可确定。基于任务计划与控制信息,可在预报阶段提前估计航天器迎风面积的变化规律。这种任务先验知识为主动建模并补偿迎风面积变化的影响提供了重要基础。

传统轨道预报方法中,常采用阻力系数查表法处理变迎风面积问题,即基于历史数据建立不同迎风面积条件下的阻力系数查找表。该方法属于静态参数化建模,难以充分适应空间环境与航天器在轨状态的动态演化特性。在上述的轨道预报框架中,查表法与动态学习伪阻力系数演变规律的机器学习范式之间存在一定的适配差异。因此,有必要构建一种既能吸收任务先验知识,又能与数据驱动模型协同工作的迎风面积处理机制。

2.2 伪阻力系数修正模型

为了使轨道预报框架能有效应对航天器变型的影响,本文建立了一种伪阻力系数修正模型。该模型基于阻力系数的面积加权定义,分析局部迎风面积变化对其整体值的扰动关系,构建了适用于有限面积变化情形的幂律近似模型。由于伪阻力系数在受迎风面积变化的影响上与物理阻力系数一致,因此模型可直接迁移用于 \bar{C}_D 的修正。

考虑航天器表面由 N_A 个离散面元构成,每个面元 i 的实际迎风面积为 A_i ,对应的阻力系数为 $C_{D,i}$,则航天器整体等效阻力系数(Dey et al., 2025)可以定义为

$$C_D = \sum_{i=1}^{N_A} w_i C_{D,i}, \quad w_i = \frac{A_i}{A}, \quad A = \sum_{i=1}^{N_A} A_i.$$

假设航天器的姿态调整仅导致子集 $s \subset \{1, \dots, N_A\}$ 的面元发生迎风面积改变。令原始迎风面积和阻力系数分别为

$$A_0 = \sum_{i=1}^{N_A} A_i, \quad C_{D,0} = \frac{1}{A_0} \sum_{i=1}^{N_A} A_i C_{D,i}.$$

变化后,对于 $i \in s$,其迎风面积变为 $A_i \rightarrow A_i + \delta A_i$,总面积变为

$$A = A_0 + \delta A,$$

其中 $\delta A = \sum_{i \in s} \delta A_i$ 。相应地,新阻力系数为

$$C_D = \frac{\sum_{i \notin s} C_{D,i} A_i + \sum_{i \in s} C_{D,i} (A_i + \delta A_i)}{A_0 + \delta A} \quad (2)$$

$$= \frac{C_{D,0} A_0 + \sum_{i \in s} C_{D,i} \delta A_i}{A_0 + \delta A}.$$

为建立 C_D 对面积变化的灵敏度关系,对式(2)

的分母在 $\delta A = 0$ 处进行一阶泰勒展开, 忽略二阶小量, 整理后得到一阶近似:

$$\delta C_D = C_D - C_{D,0} \approx \frac{1}{A_0} \sum_{i \in s} (C_{D,i} - C_{D,0}) \delta A_i. \quad (3)$$

为了进一步简化模型, 将子集 s 上的面积加权平均阻力系数定义为

$$C_{D_s} = \frac{\sum_{i \in s} C_{D,i} \delta A_i}{\sum_{i \in s} \delta A_i},$$

则式(3)可写为

$$\delta C_D \approx \frac{C_{D_s} - C_{D,0}}{A_0} \delta A.$$

将上式改写为相对变化形式, 并定义无量纲参数 α :

$$\frac{\delta C_D}{C_{D,0}} \approx -\alpha \frac{\delta A}{A_0}, \quad \alpha = 1 - \frac{C_{D_s}}{C_{D,0}}.$$

考虑到实际轨道预报中难以实时获取 C_D 随构型变化的非线性规律, 本文在局部构型变化范围内引入简化假设: α 可近似视为常数 (即 C_{D_s}/C_D 变化缓慢)。基于此, 可将有限差分推广为微分形式:

$$\frac{dC_D}{C_D} = -\alpha \frac{dA}{A}. \quad (4)$$

对式(4)从初始状态 $(A_0, C_{D,0})$ 积分至任意状态 (A, C_D) , 得:

$$\int_{C_{D,0}}^{C_D} \frac{dC'}{C'} = -\alpha \int_{A_0}^A \frac{dA'}{A'} \Rightarrow C_D = C_{D,0} \left(\frac{A_0}{A} \right)^\alpha.$$

上式可迁移应用于伪阻力系数的修正, 得到修正公式:

$$\bar{C}_D = \bar{C}_{D,0} \left(\frac{A_0}{A} \right)^\alpha. \quad (5)$$

2.3 伪阻力系数修正模型在智能轨道预报框架中的集成

伪阻力系数修正模型在智能轨道预报框架中的具体集成方式, 应确保从数据构建、智能学习到轨道预报的全过程均能有效应对构型变化的影响。

第1步: 在构建 \bar{C}_D 数据集时, 由于需采用与预报阶段完全一致的动力学模型, 每当轨道外推至迎风面积发生变化的位置时, 需基于当前优化得到的 \bar{C}_D 调用修正模型进行更新。

第2步: 在原始数据集中, 各样本的伪阻力系数 $\bar{C}_D^{(k)}$ 对应不同的迎风面积 $A^{(k)}$ 。为此, 本文采用“面积归一化—还原机制”。具体来说, 是在机器学习模型训练前, 使用修正模型对输入进行预处理, 将每个样本的 \bar{C}_D 归一化至同一参考面积 A_{ref} 下; 在预测

阶段, 利用训练好的模型预测得到 A_{ref} , 再根据预报起点航天器的实际迎风面积, 利用修正模型进行结果还原, 从而得到实际面积下 \bar{C}_D 的预测值。

第3步: 在轨道数值积分阶段, 将第2步的预测值作为初始 \bar{C}_D 。若预报期内发生计划内面积调整, 在相应时刻调用修正模型更新积分器中所使用的 \bar{C}_D 值, 确保其始终与当前迎风面积相匹配, 从而实现对整个预报弧段的高精度轨道外推。

3 仿真分析

3.1 实验数据与设置

选择某在轨大型变型航天器为研究对象。其轨道高度约 400 km, 体型较大、构型多样, 迎风面积变化显著。实验所用数据均来源于公开渠道: 空间环境参数 F10.7 和 A_p 指数数据来自美国国家海洋和大气管理局 (NOAA) 空间天气预报中心; 轨道相关数据亦基于公开星历信息处理获得。轨道预报采用龙格-库塔方法进行数值积分, 步长为 60 s, 预报时长设置为 7 d。轨道动力学模型的相关参数设置见表 1。

基于仿真数据统计分析, 修正模型中的参数 α 的经验取值范围为 0.2 ~ 0.4。针对本文研究对象, 进一步选取传统方法中预报精度高的样本, 查看其变型后阻力系数变化结果, 然后计算 α ; 通过 25 组数据, 得到本研究对象 α 的取值是 0.3 左右。因此, 本文在所有实验中取 $\alpha = 0.3$ 。

表 1 动力学模型的参数设置

Table 1 Parameter settings for the dynamic model

参数	设置
大气密度模型	NRLMSISE-00
地球引力场	64×64
第三体引力	日、月引力星历表 DE430
太阳辐射压	不考虑

实验采用 2024 年 11 月 13 日—12 月 2 日的数据作为训练集, 用于构建伪阻力系数数据集并训练预测模型。由于伪阻力系数并非仅由当日空间环境状态决定, 而是依赖于过去多日的演化历史, 本文将历史 27 d 的 F10.7 和 A_p 序列作为模型输入, 以回归目标 \bar{C}_D 。在序列建模方面, 选用标准 Transformer 编码器神经网络。相较于传统循环结构模型 (如 LSTM、GRU), 其自注意力机制无需递归计算, 可直接建模任意两个时间步之间的依赖关系, 有效缓解长序列训练中的梯度消失问题, 从而更适用于捕捉伪阻力

系数对 F10.7 和 A_p 变化的长期依赖性。神经网络的设置见表 2。

表 2 神经网络的参数设置

Table 2 Parameter settings for the neural network

参数	设置
回溯窗口	27
嵌入维数	64
注意力层数	2
注意力头数	4
前馈层大小	256
Batch Size	16
损失函数	MSE
学习率	0.001
训练轮次	100
Dropout	0.1

3.2 结果分析

从误差趋势和统计分布特性两方面评估轨道预报结果。首先,通过 1 组迎风面积显著突变的 7 天预报案例,展示智能预报框架在应对大型航天器变型时的优越性能;随后基于测试集上 20 组独立试验的统计结果,从整体上验证本文方法的可靠性。

图 3 展示了三种方法的总位置误差随预报时长的演变。竖直虚线标示了第 6 天发生的构型调整事件,变型前后迎风面积发生了较大变化。结果分析如下:

(1)传统查表法(虚线-方形):在变型前误差增长平缓,变型后虽通过查表方式及时调整了阻力系数,但仍表现出明显的误差上升趋势,至第 7 d 总位置误差达约 37 km。

(2)基础智能框架(点划线-菱形):即本文的通用智能预报方法。由于未引入修正机制,模型难以区分面积变化与空间环境扰动,在变型前已出现误差偏高现象,变型后误差迅速发散,最终达到约 85 km,表明其对大型变型航天器的适应性不足。

(3)本文方法(实线-圆形):在基础智能框架上集成了伪阻力系数修正模型。该方法使得伪阻力系数能动态适配不同迎风面积,有效抑制了因构型变化引起的偏差。在整个预报周期内,误差增长相对平稳,至第 7 d 总位置误差仅约 22 km,显著优于其他 2 种方法。

该案例表明:式(5)的修正模型不仅能够补偿

面积突变带来的物理失真,还保持了机器学习阶段对空间环境与伪阻力系数关联规律的学习效果,使智能预报框架在变构型条件下仍具备良好的预测能力。




图 3 轨道预报误差比较

Fig. 3 Comparison of orbit prediction errors

为了评估方法在构型变化场景下的适用性,本文在包含多次计划内变型事件的测试集上进行了 20 组独立的 7 天轨道预报试验。图 4 展示了三种方法的最大总位置误差的箱线图。如图所示,传统查表法(左侧箱体)的中位数约为 37 km,误差主要分布在 10~60 km 之间。基础智能框架(中间箱体)表现更差,中位数达 71 km,箱体整体上移,这表明缺乏物理信息补充导致模型泛化能力下降。本文方法(右侧箱体)的中位数降至约 26 km,四分位距收窄,说明其在所选的变型场景下能保持更可靠的预报性能。




图 4 20 组测试样例的轨道预报误差分布

Fig. 4 The distribution of orbit prediction errors for 20 test cases

综上所述,引入修正模型不仅提升了单次预报的精度,更重要的是增强了轨道智能预报框架对大型变型航天器复杂构型变化的适应能力。

4 结 论

针对大型变型航天器中长期轨道预报精度不足的问题,本文提出了一种智能预报方法。该方法引入伪阻力系数,将大气密度不确定性与阻力系数综合为可学习的时变参数。针对构型变化引起的迎风面积突变,建立了伪阻力系数的修正模型,并

将其嵌入轨道智能预报流程。仿真实验表明:所提方法的7 d轨道预报位置误差显著低于传统查表法和未考虑修正的轨道智能预报方法;20组测试样例的位置误差中位数约为26 km,所提方法显著提升了预报精度与适应性。研究成果为低轨大型航天器精密轨道预报提供了有效的技术途径。

参考文献:

- 段成林,盛庆轩,慎千慧,等,2025.空间站高精度轨道预报空间环境参数使用策略分析[J].载人航天,31(3):344-350.
- 雷骐玮,张洪波,2023.基于PPO2强化学习算法的空间站轨道预报方法[J].中国空间科学技术,43(4):93-103.
- 汪宏波,赵长印,柳仲贵,等,2016.基于误差发散规律的低轨卫星大气阻力系数计算方法[J].天文学报,57(4):447-460.
- 徐玲玲,赵航,宋静,等,2024.基于SGP4模型的空间站轨道精度分析[J].全球定位系统,49(2):98-105.
- CALABIA A, JIN S, 2021. Upper-Atmosphere Mass Density Variations From CASSIOPE Precise Orbits [J]. Space Weather, 19(4):e2020SW002645.
- CHEN X, TANG C, DAI W, et al, 2025. Modelling and prediction of atmospheric drag coefficients in LEO satellite orbit determination and prediction with Bi-LSTM approach[J]. Adv Space Res, 75(3):2874-2888.
- CIMMINO N, OPROMOLLA R, FASANO G, 2023. Machine learning-based approach for ballistic coefficient estimation of resident space objects in LEO [J]. Adv Space Res, 71(12):5007-5025.
- DEY S, RAY S, GHOSH S, et al, 2025. An extreme events study of the storm-time variations in satellite drag coefficients[J].Space Weather, 23(12):e2025SW004634.
- EMMERT J T, 2015. Thermospheric mass density: A review [J]. Adv Space Res, 56(5):773-824.
- HAO Y, LU J, PENG G, et al, 2024. F10.7 daily forecast using LSTM combined with VMD method [J]. Space Weather, 22(1):e2023SW003552.
- HUANG W B, TANG R, QU G Z, et al, 2024. An XGBoost-based method for improved orbit prediction with an orbit-separate modeling strategy [J]. IEEE Trans Aerosp Electron Syst, 60(4):4887-4895
- LI B, ZHANG Y, HUANG J, et al, 2021. Improved orbit predictions using two-line elements through error pattern mining and transferring [J]. Acta Astronaut, 188:405-415.
- LIN C, CHEN J, ZHU H, 2025. A method for compensating prediction errors to improve the orbit prediction accuracy of Starlink satellites[J]. GPS Solutions, 29(1):17.
- MONTENBRUCK O, GILL E, RACKESTAD B, et al, 2011. Orbit determination and prediction of the International Space Station[J]. J Spacecr Rockets, 48(6):1055-1067.
- National Aeronautics and Space Administration(NASA), 2025. Unique Conjunction Events [EB/OL]. [2025-01-01]. <https://www.nasa.gov/cara/unique-conjunction-events>.
- North American Aerospace Defense Command (NORAD), 2024.Space Scoreboard[EB/OL]. [2024-12-24]. <https://www.space-track.org>.
- PENG H, BAI X, 2023. A medium-scale study of using machine learning fusion to improve TLE prediction precision without external information [J]. Acta Astronaut, 204:477-491.

(责任编辑 王海蓉)