

DOI: 10.3724/zrht.1674-5825.2026024

基于Patch-Transformer的低轨卫星轨道预报研究

廖嘉豪, 徐 浩, 孟云鹤*

(中山大学人工智能学院, 珠海 519082)

摘 要: 针对大气阻力建模不确定性导致低轨卫星中长期轨道预报精度受限的问题, 提出了一种基于伪阻力系数和 Patch-Transformer 神经网络的智能轨道预报方法。引用伪阻力系数将大气阻力建模问题转化为时间序列预测任务, 采用 Patch-Transformer 神经网络捕捉空间环境参数与伪阻力系数之间的复杂映射关系, 构建了物理模型与数据驱动融合的轨道预报框架。基于 Swarm A 卫星的实验表明, 与传统方法相比, 所提方法在 7 d 预报周期内可将轨道位置误差中位数降低约 23%; 在地磁暴及太阳耀斑场景下验证表明, 所提方法在复杂空间环境条件下具有一定的适用性。

关键词: 轨道预报; 空间环境参数; 大气阻力; 机器学习

中图分类号: V412.4 **文献标识码:** A **文章编号:** 1674-5825(2026)02-0236-08

Research on LEO Satellite Orbit Prediction Based on Patch-Transformer

LIAO Jiahao, XU Hao, MENG Yunhe*

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

Abstract: Low earth orbit satellites have limited accuracy in medium and long-term orbit prediction owing to uncertainties in atmospheric drag modeling. To address this limitation, an intelligent orbit prediction method based on the pseudo-drag coefficient and Patch-Transformer neural network is proposed. The pseudo-drag coefficient transforms the atmospheric drag modeling problem into a time-series prediction task. The Patch-Transformer neural network captures the complex mapping relationship between the pseudo-drag coefficient and space environment parameters, thereby establishing an orbit prediction framework that integrates physical models with data-driven approaches. The experimental results—based on the Swarm A satellite—demonstrated that, compared with traditional method, the proposed method reduced the median orbit position error by approximately 23% within a 7 d prediction period. Validation under geomagnetic storm and solar flare scenarios further indicated that the proposed method has a certain degree of applicability under complex space environment conditions.

Key words: orbit prediction; space environment parameters; atmospheric drag; machine learning

1 引言

近年来, 商业航天的快速发展和卫星发射数量的激增使低地球轨道空间日益拥挤, 这对空间

态势感知与精密轨道预报提出了前所未有的要求。根据北美航空航天防御司令部的数据, 截至 2024 年, 已编目的空间物体超过 47 000 个, 包括卫星、

收稿日期: 2026-02-10; 修回日期: 2026-03-26

基金项目: 智控实验室开放基金项目 (ICL-2023-0403)

第一作者: 廖嘉豪, 男, 硕士研究生, 研究方向为空天智能。E-mail: liaojh28@mail2.sysu.edu.cn

* 通讯作者: 孟云鹤, 男, 博士, 教授, 研究方向为智能预报和智能博弈。E-mail: mengyh7@mail.sysu.edu.cn

引用格式: 廖嘉豪, 徐浩, 孟云鹤. 基于Patch-Transformer的低轨卫星轨道预报研究[J]. 载人航天, 2026, 32 (2): 236-243. Liao J H, Xu H, Meng Y H. Research on LEO satellite orbit prediction based on Patch-Transformer[J]. Manned Spaceflight, 2026, 32 (2): 236-243.

航天器及碎片^[1]。与此同时, 近地空间物体之间的接近事件发生频率急剧上升。NASA 报告显示, 仅 2024 年 12 月就记录了约 19 000 次接近事件 (含碎片、有效载荷及大型星座事件), 几乎是 2023 年同期数量的 2 倍^[2]。在此背景下, 实现准确、可靠的中长期轨道预报对于规避碰撞风险、保障航天器在轨安全与空间环境的可持续利用具有至关重要的意义。

传统的轨道预报方法通常遵循轨道确定—轨道预报的两阶段模式。首先, 利用观测数据精确估计初始轨道参数, 而后结合动力学模型进行数值外推。对于低轨卫星而言, 大气阻力是影响预报精度的最主要摄动源, 其计算精度直接取决于大气密度模型和阻力系数的准确性^[3]。然而, 现有的大气密度模型 (如 MSIS 系列、DTM 系列等) 在描述热层密度随太阳活动、地磁扰动等空间环境参数变化的复杂响应时仍存在偏差, 且这些环境参数本身的长期预测具有很大的不确定性。此外, 传统方法通常将轨道确定阶段估计的阻力系数用于预报期间, 这种做法使得 2 个参数存在时间上的不匹配, 且难以适应空间环境的动态变化, 导致中长期预报中的误差不断累积。

为克服传统方法的局限, 研究人员将人工智能技术应用于轨道预报领域。主流方法可分为 2 类: ①基于历史误差建模的数据驱动补偿方法, 通过经典机器学习模型学习并补偿传统力学模型的预报误差^[4-6], 以及利用深度神经网络对误差时序特征进行学习并修正^[7-9]; ②基于物理机制的大气密度模型改进方法, 包括利用机器学习技术预测 F10.7 等关键空间环境参数^[10-12]、对弹道系数与阻力调制系数进行估计与修正^[13-15], 以及直接对大气阻力系数及热层大气密度进行建模与预测^[16,17]。这些研究为轨道预报领域的创新发展奠定了重要基础。

针对传统方法在中长期预报中大气阻力建模不确定性的局限, 本文提出一种基于伪阻力系数和 Patch-Transformer 神经网络的智能轨道预报方法。引用伪阻力系数, 将大气密度与阻力系数综合为时变的等效参数, 将大气阻力建模难题转化为时间序列预测问题; 采用 Patch-Transformer 神经网络建立从历史空间环境参数到未来伪阻力系数的映射, 以规避对未来空间环境参数独立预报

所带来的误差; 最终将预测得到的伪阻力系数代入高精度轨道动力学模型进行数值积分, 构建以物理模型为骨架, 以数据智能为核心的轨道预报框架。

2 基于伪阻力系数的轨道预报框架

2.1 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见式 (1)。

$$\ddot{\mathbf{r}} = -\mu \frac{\mathbf{r}}{r^3} + \mathbf{a}_p \quad (1)$$

其中, $\mathbf{r}$ 、 $\dot{\mathbf{r}}$ 、 $\ddot{\mathbf{r}}$ 分别为卫星位置、速度与加速度向量, μ 为地球引力常数, $\mathbf{a}_p$ 为摄动加速度, 包括非球形引力、第三体引力、大气阻力、太阳光压等。在低轨卫星轨道预报中, 大气阻力是主要的非保守力, 其表达式见式 (2)。

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

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, $\mathbf{v}_e$ 为卫星相对于大气的速度矢量。

2.2 伪阻力系数的定义与优势

传统轨道预报方法在计算大气阻力加速度时, 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 F10.7、 A_p) 的预报值, 估算未来时段的大气密度; 其次, 在轨道确定阶段估算阻力系数, 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下, 其局限性逐渐凸显。例如, 预报阶段的大气密度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, 且与模型自身的结构误差叠加, 导致密度的估计精度显著下降。此外, 阻力系数作为定轨阶段的最优估计, 其值吸收了大气密度模型、卫星面质比等误差, 与大气密度模型形成了一个自洽系统^[18]。因此, 在预报阶段, 阻力系数的适用性就会受到挑战, 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, 本文引用伪阻力系数 (记为 $\bar{C}_D$) 的概念^[19]。其核心思想是将大气密度的不确定性以及传统阻力系数的不适用性整合为统一的等

效参数。其计算过程为：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。卫星受到的大气阻力加速度可重新表示为式（3）。

$$\mathbf{a}_{\text{drag}}^* = -\frac{1}{2} \left(\frac{A}{m} \right) \rho^* \bar{C}_D \mathbf{v}_e \mathbf{v}_e \quad (3)$$

由于式（3）中的 ρ^* 是一个基于固定空间环境参数的、无须预测的已知量，因此轨道预报精度的提升问题可转化为对伪阻力系数的精确预测问题，这为应用数据驱动方法确定了研究方向。

2.3 基于伪阻力系数的轨道预报流程

基于伪阻力系数的概念，本文构建了一个智能轨道预报框架，其完整工作流程如图 1 所示。该框架将物理模型与数据驱动方法深度融合，具体包含 3 个阶段。

1) 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，这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 ，利用从历史时刻 T_{-M} 到 T_0 （ $M \gg N$ ）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 $\{\bar{C}_D(T_{-M}), \bar{C}_D(T_{-M+1}), \dots, \bar{C}_D(T_{-N})\}$ 。

2) 伪阻力系数的智能学习和预测。该阶段的目标是将第一阶段构建的数据集输入到一个学习

模型中，训练其掌握从输入特征到目标变量的复杂映射关系，从而能够对未来时刻的伪阻力系数进行精准预测。

3) 轨道数值积分与预报。该阶段是框架的最终输出。将第二阶段预测得到的 $\bar{C}_D(T_0)$ 基于公式（3）代入到与第一阶段一致的高精度轨道动力学模型中，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。

针对第二阶段的预测任务建模，其本质可归结为一个时间序列预测问题：利用历史的伪阻力系数序列及对应的驱动因素（如空间环境参数）来预测未来某一时刻的伪阻力系数值。理论上，适用于此类任务的方法很多，可从传统的自回归差分移动平均模型（Autoregressive Integrated Moving Average, ARIMA）到现代的机器学习模型，如梯度提升树（Extreme Gradient Boosting, XGBoost）、支持向量回归（Support Vector Regression, SVR），乃至深度学习方法，如循环神经网络（Recurrent Neural Network, RNN）、长短期记忆网络（Long Short-Term Memory, LSTM）。而本文采用深度学习方法中的 Patch-Transformer 神经网络模型，通过历史的空间环境参数 F10.7 和 Ap 预测目标伪阻力系数。

3 基于 Patch-Transformer 的伪阻力系数预测模型

在本文的轨道预报框架中，第二阶段的核心




图 1 基于伪阻力系数的轨道预报流程图

Fig. 1 Orbit prediction flowchart based on the pseudo-drag coefficient

任务在于构建一个能够准确预测伪阻力系数的机器学习模型。该预测模型的精度直接决定了最终轨道预报的准确性。伪阻力系数是一个综合反映空间环境扰动的变量, 其变化同时受到空间环境短期突变 (如地磁暴引发的剧烈扰动) 和长期周期 (如太阳 27 d 自转周期) 模式的共同影响。因此, 预测模型的选取必须能够有效捕捉此类复杂的依赖关系。

3.1 模型选型依据

传统循环神经网络 (如 RNN、LSTM 等) 在时间序列预测中应用广泛, 但其序列式计算机制限制了并行效率, 并且在处理长序列时容易出现长期依赖信息衰减的问题。Transformer 架构凭借其自注意力 (Self-Attention) 机制能够直接建模任意时间位置之间的依赖关系, 在长序列建模中具有优势^[20]。然而, 将标准 Transformer 直接应用于时间序列预测也存在挑战: ①将每个时间步视为独立词元 (token) 的处理方式, 可能忽略局部连续时间段内蕴含的物理模式 (如连续数日太阳活动的变化过程); ②点式注意力机制会带来较高的计算复杂度。

近年来, 基于 Patch 划分思想的时间序列预测方法受到关注。其中, 以 PatchTST 为代表的 Patch-based Transformer 模型通过将连续时间序列划分为若干局部子序列 (Patch), 再利用 Transformer 进行建模, 在长期预测任务中取得了良好效果^[21]。该类方法能够在保留全局依赖建模能力的同时增强局部特征提取能力, 适合同时包含短期扰动与长期周期变化的时间序列数据。

与其他常用的深度学习方法相比, Patch-based Transformer 模型具有以下优势: 相比 RNN、LSTM 等循环结构, 其自注意力机制支持并行计算, 训练效率更高, 且对长期依赖关系的捕捉能力更强; 相比标准 Transformer, Patch 划分机制将相邻时间步聚合为局部子序列, 既降低了注意力计算的复杂度, 又增强了模型对短期局部模式 (如太阳活动趋势或地磁扰动过程) 的感知能力; 相比多层感知机 (Multi-Layer Perceptron, MLP) 等前馈神经网络, 其对时序结构的显式建模使其更适合具有周期性和非平稳特征的空间环境参数序列。

受上述分析启发, 本文采用基于 Patch 划分的

Transformer 模型用于伪阻力系数预测。所用模型并未直接使用 PatchTST 的原始模型或代码, 而是针对伪阻力系数预测任务的特点对模型结构进行了重新设计与实现, 使其能够处理空间环境参数驱动的预测问题。本文研究的重点在于将 Patch-Transformer 架构引入轨道预报, 并探索其在物理模型与数据驱动融合中的应用效果。

3.2 模型结构概述

本文 Patch-Transformer 模型的核心工作流程是将输入的 F10.7 和 Ap 序列映射为目标时刻的伪阻力系数预测值。其模型架构如图 2 所示, 主要包含 3 个核心步骤。




图 2 Patch-Transformer 模型架构
Fig. 2 Patch-Transformer model architecture

1) 输入与 Patch 划分。设输入序列长度为 L , 特征维度为 d 。采用滑动窗口方式将原始时间序列划分为若干重叠的局部子序列, 每个 Patch 包含连续 P 个时间步的数据, 其中, P 为 Patch 长度。相邻的 Patch 之间按照固定步长移动, 从而得到若干个 Patch 的序列表示。该过程将原始时间序列重组为具有局部时间上下文信息的子序列集合, 使模型能够显式感知短期环境变化模式。

2) 特征嵌入与位置编码。每个 Patch 经展平后通过可学习的线性映射投影到高维特征空间, 得到对应的 Patch 嵌入向量。该过程相当于对局部时间片段进行特征提取, 使模型能够从原始数据中学习具有物理意义的表示。由于 Patch 划分后序列被重组为无序的子序列集合, 模型无法直接感知各 Patch 在原始序列中的位置, 因此进一步为每个 Patch 添加位置编码 (Position Encoding), 以保留其位置关系。

3) Transformer 编码与预测输出。嵌入后的

Patch 序列被输入由 H 层 Transformer 编码器堆叠构成的核心模块。每层编码器包含多头自注意力机制 (Multi-Head Attention) 和前馈神经网络 (Feed Forward)，并通过残差连接与层归一化 (Add & Norm) 进行特征融合与稳定训练。自注意力机制的核心计算公式见式 (4)。

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4)$$

其中, Q 、 K 、 V 分别为查询、键、值矩阵, 由输入序列线性变换而来; d_k 为矩阵 K 的维度, 用于缩放点积, 以防止梯度消失; Softmax 函数对缩放后的点积结果进行归一化, 得到注意力权重。自注意力机制通过计算序列中各 Patch 之间的相关性权重, 使模型能够在更新每个 Patch 表示时综合考虑全局信息, 从而捕捉跨时间尺度的依赖关系。经过多层编码处理后, 模型可获得对整个历史序列的综合表征。最后, 编码器输出的特征向量经线性输出层 (Linear Head) 映射为目标时刻的伪阻力系数预测值。

4 仿真实验

为验证本文所提方法的有效性, 以 Swarm A 卫星为对象进行轨道预报精度分析。Swarm A 是欧空局 (European Space Agency, ESA) 于 2013 年发射的低轨地球科学卫星, 轨道高度约 450 km, 其主要任务是研究地球磁场与空间环境。该卫星所处的轨道区域受大气阻力影响显著, 且其精密星历数据公开可用, 是验证低轨卫星轨道预报方法的理想平台。

4.1 实验数据与设置

实验采用的 Swarm A 卫星精密星历数据来源于 ESA。空间环境参数 F10.7 和 Ap 指数数据来自美国国家海洋和大气管理局 (National Oceanic and Atmospheric Administration, NOAA) 空间天气预报中心。预报时长设置为 7 d。

实验以 2024 年 1 月 1 日至 10 月 12 日的数据作为训练集, 用于构建伪阻力系数数据集并训练 Patch-Transformer 模型。以 2024 年 10 月 12 日至 12 月 20 日的数据作为测试集, 用于评估模型在未见数据上的轨道预报性能, 其中, 在剔除异常数据后共得到 50 个测试样例。动力学模型参数设置见表 1, 神经网络超参数设置见表 2。

表 1 动力学模型参数设置

Table 1 Parameter settings for the dynamic model

参数类别	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

表 2 神经网络参数设置

Table 2 Parameter settings for the neural network

参数类别	参数设置
回溯窗口	27
Patch 长度	3
Patch 嵌入大小	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

对比基准方法采用传统的数值积分轨道预报方法: 以 NRLMSISE-00 为大气密度模型, 在轨道确定阶段通过最小二乘法估计阻力系数, 并将该估计值在整个 7 天预报期间保持恒定; 预报阶段所需的 F10.7 和 Ap 指数预报值来源于空间环境预报中心 (Space Environment Prediction Center, SEPC)。2 种方法采用相同的初始轨道状态、高精度动力学模型配置 (见表 1) 以及数值积分器 (7/8 阶龙格-库塔法, 积分步长 60 s), 以确保对比实验的公平性。

4.2 轨道预报结果分析

本文从误差演变趋势和统计分布特性 2 个维度对轨道预报结果进行综合评估。首先, 通过一组预报案例展示本文方法在提升中长期预报精度方面的效果; 随后, 基于测试集上 50 组独立实验的统计结果, 从统计意义上验证本文方法的可靠性。

图 3 展示了一组 7 d 的预报案例, 传统定轨方法与所提方法在总位置误差方面的演变对比。由图 3 可知, 传统方法的误差 (蓝色方点曲线) 随预报时长呈现近似指数型的快速增长趋势。在预报初期 (第 1~2 天), 其误差尚处于较低水平, 但自第 3 天起, 误差开始显著攀升, 至预报终点第 7 天时, 总位置误差已达约 30 km。这种误差的快速增长正是传统大气阻力模型在中长期预报中逐渐失效的典型表现。相比之下, 本文方法 (红色圆点曲线) 在整个 7 d 预报周期内总位置误差始




图 3 轨道预报误差比较
Fig. 3 Orbit prediction error comparison

终维持在较低水平, 误差曲线未出现明显的突变或加速增长阶段。值得注意的是, 在本案例 3 d 以内的短期预报阶段, 传统方法的误差水平略优于本文方法。这与本文伪阻力系数的建模设置有关: 实验以 7 d 为预报周期构建伪阻力系数, 使其成为整个预报时段大气阻力状态的综合等效表征, 而非针对短期的精确刻画, 因此在个别情况下, 短期预报阶段的局部适应性可能不及传统方法。

为从统计意义上系统评估轨道预报方法的性能, 在测试集上共进行了 50 组独立的预报实验。图 4 是 2 种方法在 7 d 预报的最大总位置误差分布箱线图。从图中可看出, 传统方法 (蓝色箱线) 的误差分布较分散, 其中位数位于约 21 km 处, 误差主要分布在 10~37 km 的较宽范围内。相比之下, 本文方法 (红色箱线) 的误差分布整体向低误差方向显著偏移, 中位数降至约 16 km, 较传统方法下降约 23%, 误差主要集中在约 9~31 km 的更优区间内, 箱体更加紧凑, 表明本文方法的预报稳健性较传统方法有所提升。




图 4 50 组测试样例的轨道预报误差分布
Fig. 4 Distribution of orbit prediction errors for 50 test cases

上述结果表明, 本文方法在 50 组测试样例中整体上实现了对传统方法的精度提升, 验证了其

在中长期轨道预报中的可行性。此外, 在计算效率方面, 以下耗时均基于 CPU 单机环境测试: 数据集构建阶段需对每个样本独立求解伪阻力系数, 平均每个样本耗时约 110 s, 初始数据集构建完成后, 新增样本仅需单独优化一次即可完成数据集更新; Patch-Transformer 模型的离线训练总耗时约为 6 min, 单次神经网络推断耗时约 6 ms, 7 d 轨道数值积分耗时约 1.3 s, 上述计算均可离线完成, 整体计算开销在工程应用中具有一定的可行性。

4.3 复杂空间环境条件下的结果分析

与 4.2 节的测试样例对应的地磁活动整体处于平静或中等水平, 尚未充分覆盖强地磁扰动、太阳耀斑等极端空间环境场景。而地磁暴、太阳耀斑等复杂空间环境条件是大气阻力建模的核心难点, 也是检验轨道预报方法稳健性的重要场景。为此, 选取数据集中 3 个复杂空间环境场景开展补充验证实验, 以评估本文方法在极端条件下的适用性。

针对每个场景, 以扰动事件发生日为预报起始时刻, 利用该时刻之前的历史数据构建伪阻力系数数据集并训练模型, 进行 7 d 轨道预报, 并与传统方法的预报结果进行对比。3 个场景的空间环境特征如表 3 所示。

表 3 复杂空间环境场景参数
Table 3 Parameters of complex space environment scenarios

场景	预报起始时间	事件类型	F10.7 指数	Ap 指数
1	2024-08-12	地磁暴	272	122
2	2024-10-03	太阳耀斑	312	8
3	2024-10-10	地磁暴	216	96

图 5、图 6 和图 7 分别展示了 3 个场景下 2 种方法的 7 d 总位置误差演变对比。场景 1 中, 2 种方法误差均较大且接近, 传统方法约 75 km, 本文方法约 71 km, 差距相对有限; 场景 2 中, 2 种方法误差整体处于较低水平, 本文方法约 15 km, 略优于传统方法约 17 km; 场景 3 中, 传统方法误差随预报时长快速增长, 至第 7 天达约 55 km, 而本文方法将误差控制在约 22 km, 优势较为明显。

综合 3 个场景的验证结果可以看出, 在复杂空间环境条件下, 本文方法在部分场景中表现出一定的精度优势。然而, 场景 1 的结果表明, 在极端扰动条件下, 2 种方法的误差均显著增大,




图 5 场景1的轨道预报误差比较

Fig. 5 Orbit prediction error comparison for scenario 1




图 6 场景2的轨道预报误差比较

Fig. 6 Orbit prediction error comparison for scenario 2




图 7 场景3的轨道预报误差比较

Fig. 7 Orbit prediction error comparison for scenario 3

本文方法的优势并不突出,表明本文方法在强扰动环境下的适用边界与稳健性仍有待进一步研究。受限于验证场景数量有限,本文方法在复杂空间环境下的系统性评估将作为后续工作的重点方向之一。

5 结论

1) 引用伪阻力系数的概念,将大气密度与阻力系数的不确定性综合为统一的等效参数,把复杂的大气阻力建模问题转化为时间序列预测任务,避免了传统方法对未来空间环境参数预报的直接依赖。

2) 将 Patch-Transformer 神经网络模型引入伪阻力系数预测任务。基于 Swarm A 卫星 50 组测试

样例的统计结果表明,与传统方法相比,本文方法在 7 d 预报周期内可将轨道位置误差中位数降低约 23%,误差分布更加集中。

3) 在地磁暴及太阳耀斑场景下的验证结果表明,本文方法在部分复杂空间环境条件下具有一定的精度优势,但在极端扰动场景下误差仍显著增大,本文方法的适用边界与稳健性仍有待进一步研究。此外,实验以 7 d 为预报周期构建伪阻力系数,在个别情况下,短期预报的局部适应性可能不及传统方法,未来工作将探索多时间尺度伪阻力系数的构建策略,并进一步完善所提方法在复杂空间环境下的性能评估。

参考文献 (References)

- [1] North American Aerospace Defense Command (NORAD). Space scoreboard[EB/OL]. (2024) [2025-12-12]. <https://www.space-track.org>.
- [2] National Aeronautics and Space Administration (NASA). Unique conjunction events[EB/OL]. (2025) [2025-12-12]. <https://www.nasa.gov/cara/unique-conjunction-events>.
- [3] Emmert J T. Thermospheric mass density: A review[J]. Advances in Space Research, 2015, 56 (5): 773-824.
- [4] Li B, Zhang Y, Huang J, et al. Improved orbit predictions using two-line elements through error pattern mining and transferring[J]. Acta Astronautica, 2021, 188: 405-415.
- [5] Peng H, Bai X. A medium-scale study of using machine learning fusion to improve TLE prediction precision without external information[J]. Acta Astronautica, 2023, 204: 477-491.
- [6] Huang W, Tang R, Qu G, et al. An xgboost-based method for improved orbit prediction with an orbit-separate modeling strategy[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60 (4): 4887-4895.
- [7] 李欣怡, 陈昭岳, 徐明, 等. 基于机器学习的卫星轨道预测混合模型研究[J]. 宇航学报, 2024, 45 (11): 1766-1774.
Li X Y, Chen Z Y, Xu M, et al. Research on hybrid model of satellite orbit prediction based on machine learning[J]. Journal of Astronautics, 2024, 45 (11): 1766-1774 (in Chinese).
- [8] Lin C, Chen J, Zhu H. A method for compensating prediction errors to improve the orbit prediction accuracy of Starlink satellites[J]. GPS Solutions, 2025, 29 (1): 17.
- [9] 艾彦旭, 岳承磊, 汪雪川, 等. 基于双向LSTM网络的低轨航天器轨道预报方法[J]. 宇航学报, 2025, 46 (10): 2054-2064.
Ai Y X, Yue C L, Wang X C, et al. Bi-LSTM network-based orbit prediction method for LEO spacecraft[J]. Journal of Astronautics, 2025, 46 (10): 2054-2064 (in Chinese).
- [10] 杨旭, 朱亚光, 杨升高, 等. LSTM神经网络在太阳F10.7射电流量中期预报中的应用[J]. 空间科学学报, 2020, 40 (2): 176-185.
Yang X, Zhu Y G, Yang S G, et al. Application of LSTM neural network in medium-term prediction of solar F10.7 flux[J].

- Chinese Journal of Space Science, 2020, 40 (2): 176-185 (in Chinese).
- [11] 闫帅楠, 李雪宝, 董亮, 等. 基于BiLSTM-Attention的F10.7指数预测模型与中国自主数据集的应用[J]. 空间科学学报, 2024, 44 (2): 251-261.
Yan S N, Li X B, Dong L, et al. Application of F10.7 index prediction model based on BiLSTM-Attention and Chinese autonomous dataset[J]. Chinese Journal of Space Science, 2024, 44 (2): 251-261 (in Chinese).
- [12] Hao Y, Lu J, Peng G, et al. F10.7 daily forecast using LSTM combined with VMD method[J]. Space Weather, 2024, 22 (1): e2023SW003552.
- [13] 苍中亚, 薛炳森, 程国生, 等. 大气阻力参数修正对低轨空间目标轨道预报精度的改进[J]. 空间科学学报, 2016, 36 (2): 188-195.
Cang Z Y, Xue B S, Cheng G S, et al. Improvement of orbit prediction accuracy of LEO objects by atmospheric drag parameter correction[J]. Chinese Journal of Space Science, 2016, 36 (2): 188-195 (in Chinese).
- [14] Cimmino N, Oromolla R, Fasano G. Machine learning-based approach for ballistic coefficient estimation of resident space objects in LEO[J]. Advances in Space Research, 2023, 71 (12): 5007-5025.
- [15] 雷骐玮, 张洪波. 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, 2023, 43 (4): 93-103.
Lei Q W, Zhang H B. Orbit prediction method for space station based on PPO2 algorithm of reinforcement learning[J]. Chinese Space Science and Technology, 2023, 43 (4): 93-103 (in Chinese).
- [16] Chen X, Tang C, Dai W, et al. Modelling and prediction of atmospheric drag coefficients in LEO satellite orbit determination and prediction with Bi-LSTM approach[J]. Advances in Space Research, 2025, 75 (3): 2874-2888.
- [17] 曹庆鹏, 黄柳朋, 韦春博, 等. 基于SegRNN的热层大气密度经验模型校准[J]. 空间科学学报, 2025, 45 (6): 1460-1470.
Cao Q P, Huang L P, Wei C B, et al. Calibration of thermospheric atmospheric density empirical model based on SegRNN[J]. Chinese Journal of Space Science, 2025, 45 (6): 1460-1470 (in Chinese).
- [18] 汪宏波, 赵长印, 柳仲贵, 等. 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, 2016, 57 (4): 447-460.
Wang H B, Zhao C Y, Liu Z G, et al. The method for calculating atmospheric drag coefficient based on the characteristics of along-track error in LEO orbit prediction[J]. Acta Astronomica Sinica, 2016, 57 (4): 447-460 (in Chinese).
- [19] Xu H, Luo Y, Hu H, et al. A medium and long-term intelligent orbit prediction method for LEO satellites based on segmented pseudo-drag coefficients[J]. Advances in Space Research, 2025, 76 (1): 519-532.
- [20] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. Long Beach, CA: NIPS, 2017: 5998-6008.
- [21] Nie Y, Nguyen N H, Sinthong P, et al. A time series is worth 64 words: Long-term forecasting with transformers[EB/OL]. (2023-03-05) [2025-12-12]. <https://arxiv.org/abs/2211.14730>.

(责任编辑: 高慧)