

HU Kaihui, CHEN Junyu, LIN Chusen, LI Zijie, WU Yao, WEN Zhangyi. High-precision Orbit Synthesis of Two-line Elements Based on Long Short Term Memory Network (in Chinese). *Chinese Journal of Space Science*, 2026, 46(3): 762–775. CSTR:32142.14.cjss.2025-0093. DOI:10.11728/cjss2026.03.2025-0093

基于长短期记忆网络的两行根数 高精度轨道合成*

胡开辉¹ 陈俊宇¹ 林初森² 李梓杰¹
吴 尧¹ 文章义¹

1(昆明理工大学国土资源工程学院 昆明 650093)

2(武汉大学测绘学院 武汉 430079)

摘 要 为提升 TLE (两行根数) 在轨道预报中的精度, 解决传统多项式拟合和物理建模方法在难以处理轨道非线性演化趋势时的问题, 提出一种基于长短期记忆网络 (LSTM) 的高精度 TLE 轨道参数拟合方法, 利用历史 TLE 数据对轨道要素进行高精度时间序列拟合与轨道合成. 采用 LSTM 神经网络对 TLE 轨道参数进行时间序列建模, 并结合多项式拟合形成混合建模策略. 实验以 87 个铱星 33 碎片的 TLE 数据为基础, 构建拟合模型并生成合成 TLE 利用 SGP4 传播器正向传播位置误差. 实验结果表明, 常规时段 81 个碎片合成 TLE 传播 7 天位置误差改善目标占比达 65.43%~88.89%, 误差分布更集中稳定; 磁暴期间 65 个碎片的合成 TLE 传播 3 天位置误差改善目标占比为 70.77%~80.00%, 误差波动范围低于原始 TLE. 基于 LSTM 的 TLE 轨道合成方法在捕捉轨道参数非线性演化方面表现优越, 结合角度线性化和平滑滤波策略, 提高了轨道参数拟合的精度与稳定性.

关键词 长短期记忆, 轨道合成, 两行根数, 时间序列拟合

中图分类号 V448.22

High-precision Orbit Synthesis of Two-line Elements Based on Long Short Term Memory Network

HU Kaihui¹ CHEN Junyu¹ LIN Chusen²
LI Zijie¹ WU Yao¹ WEN Zhangyi¹

1(Faculty of Land and Resources Engineering, Kunming University of Science and Technology, Kunming 650093)

2(School of Geodesy and Geomatics, Wuhan University, Wuhan 430079)

Abstract To improve the accuracy of TLE (Two Line Elements) in orbit prediction and solve the problem of traditional polynomial fitting and physical modeling methods being difficult to handle the

* 国家自然科学基金项目 (12303081), 航空科学基金项目 (20240058153001), 云南省基础研究计划项目 (202301AT070159) 和空间目标感知全国重点实验室开放基金项目 (STA2024ZCA0102) 共同资助

2025-06-13 收到原稿, 2025-09-10 收到修定稿

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

nonlinear evolution trend of orbits, a high-precision TLE orbit parameter fitting method based on Long Short Term Memory (LSTM) network is proposed. TLEs are widely applied in orbit prediction and space situational awareness because of their simplicity and accessibility, yet their accuracy deteriorates quickly when propagated forward due to perturbations such as atmospheric drag, solar activity, and Earth's nonspherical gravity field. Therefore, developing a data-driven strategy that can capture the hidden dynamics and extend the validity of TLE prediction has significant practical value. Historical TLE data is used for high-precision time series fitting and orbit synthesis of orbit elements. LSTM neural network is used to model the time series of TLE orbit parameters, and a mixed modeling strategy is formed by combining polynomial fitting. Based on the TLE data of 87 Iridium 33 fragments, a fitting model was constructed and a synthetic TLE was generated using SGP4 (Simplified General Perturbations 4) propagator to propagate position error in the forward direction. The experimental results show that the proportion of the target for improving the position error of 81 fragments in the synthesized TLE propagation for 7 days during the conventional period is 65.43%~88.89%, and the error distribution is more concentrated and stable. The proportion of the target for improving the position error of the synthesized TLE propagation of 65 fragments during a geomagnetic storm for 3 days is 70.77%~80.00%, and the error fluctuation range is lower than that of the original TLE. The TLE orbital synthesis method based on LSTM performs excellently in capturing the nonlinear evolution of orbital parameters. By combining angle linearization and smooth filtering strategies, the accuracy and stability of orbital parameter fitting are improved.

Key words Long Short Term Memory (LSTM) network, Orbital synthesis, Two-line elements, Time series fitting

0 引言

随着航天技术的飞速发展, 空间探索活动愈发频繁, 空间环境日益复杂, 目前仍处于空间碎片的高密度阶段, 空间碎片的增长速度很快. 在这种情况下, 卫星的轨道预报对于空间态势感知非常重要^[1]. 根据欧洲航天局空间碎片办公室的估算数据, 地球轨道上尺寸在 10 cm 以上的大碎片约有 3 万个, 1~10 cm 的中等碎片约有 100 万个, 小于 1 cm 的小碎片约有 1.3 亿个^[2]. 2021 年 3 月 6 日 Galileo 卫星 GSAT0219 (2018-060 C) 在欧洲空间监视系统 (EU Space Surveillance and Tracking, EUSST) 的支持下采取了轨道机动措施, 规避了 NOARD 编号为 20170 的碎片, 并于 3 月 19 日恢复正常, 该事件为伽利略卫星的首次碰撞规避事件, 具有标志性的意义^[3]. 随着空间碎片的持续增加和空间碎片管理计划的发展, 更准确地预测轨道是必要的. 精确预报轨道对于确保卫星的安全运行、优化任务调度以及提升服务质量具有重要意义^[4]. 然而, 传统的轨道预报方法在面对复杂的空间环境、非线性的轨道变化和不确定性的扰动因素时, 往往存在较大的局限性^[5]. 因此, 探索新的

轨道预报方法成为当前研究的热点.

在轨道预报方面, 传统的基于两行根数 (Two Line Elements, TLE) 和简化通用摄动 4 (Simplified General Perturbations 4, SGP4) 模型的方法虽应用广泛, 但存在精度随时间下降的问题, 尤其在低轨道更为明显^[5]. 近年来, 机器学习方法在时间序列预测领域取得了显著进展^[6-9]. 为解决这一问题, Li 等^[7]提出通过挖掘和传递轨道误差模式来改进 TLE 的轨道预报, 利用梯度提升决策树 (Gradient Boosting Decision Tree, GBDT) 和卷积神经网络 (Convolutional Neural Networks, CNN) 对历史 TLE 数据进行学习建模, 实验结果表明该方法能大幅提高未来 14 天轨道预报的精度, 沿轨道方向精度提升超 75%, 交叉轨道和径向方向提升超 90%. Chang 等^[8]基于 Levenberg-Marquardt 算法构建人工神经网络 (Artificial Neural Network, ANN) 进行卫星轨道预测, 相比传统一阶导数方法, 该方法在预测精度上有显著提升, 在与支持向量机 (Support Vector Machine, SVM) 的对比实验中, 对卫星状态变量的预测误差降低 4.5%~5%. Osama 等^[10]提出基于 LSTM (长短期记忆网络) 的卫星轨道预测方法, 利用 TLE 数据训练模

型预测卫星轨道位置和速度向量, 实验结果显示预测精度较高, 位置预测的 R^2 达到 98%, 位置均方误差为 9.7×10^{-5} , 速度预测的 R^2 也为 98%. Draček 等^[11]构建了基于 LSTM 自编码器的无监督异常检测框架, 通过对 TLE 数据预处理及模型训练, 能有效检测卫星轨道异常, 在包含已知机动事件的小数据集上验证了该方法对大小规模机动的准确检测能力. Li 等^[12]提出了一种基于多模态长短期记忆的多普勒频偏预补偿算法 (MLSTM-DPC), 仿真结果表明 MLSTM-DPC 算法的有效频偏比对照算法提高了 36.39%. 其中 LSTM 神经网络以其独特的记忆机制和强大的非线性拟合能力^[13], 通过引入门控机制和细胞状态, 能够有效地捕捉序列数据中的长期依赖关系, 并对复杂的非线性变化进行建模. 因此, 将 LSTM 神经网络应用于轨道合成, 有望克服传统方法的局限性, 提高预测精度和稳定性.

铱星 33 (Iridium 33) 与俄罗斯卫星宇宙 2251 在 2009 年 2 月发生碰撞^[14], 产生了大量空间碎片. 铱星 33 碎片云已经存在十多年, 提供了研究不同大小碎片在各种轨道扰动影响下长期演化行为的独特机会, 本文通过对这一事件产生的空间碎片 TLE 数据进行参数拟合, 提升轨道合成精度, 主要研究内容包括数据处理、铱星 33 卫星碎片的 TLE 合成方法和铱星 33 碎片 TLE 合成结果及分析.

1 数据处理

数据处理相关工作是构建从 Space-Track^{*} 网站获取的铱星 33 空间碎片 TLE 数据到模型输入的完整数据预处理流程. 这里提出一套系统化的数据预处理方法, 包括轨道要素提取、角度参数线性化展开以

及 Savitzky-Golay 滤波平滑, 解决轨道参数中的周期性跳变和随机噪声问题.

1.1 TLE 数据

TLE 是北美防空司令部 (North American Aerospace Defense Command, NORAD) 发布空间目标轨道状态的一种平均轨道根数格式^[15], 用于描述地球各轨道上卫星或空间碎片的运行位置参数, 包含卫星名称、升交点赤经、轨道倾角、轨道周期等参数. 以 NORAD 编号为 33773 的空间目标 2024 年 10 月 11 日 10:18 UTC 的 TLE 数据为例, 其格式如下.

```
1      33773U      97051L      24285.42931793
.00038843 00000-0 11860-1 0 9997
2      33773      86.4001      241.3039      0013476
118.3128 241.9433 14.41617791 82192 0
```

第一行中 33773 为空间目标编号, U 为安全保密级别; 97051 L 为国际标识符, 97 为发射年度, 051 为该年度发射序列, L 为发射产生的目标序列号; 24285.42931793 为历元时刻, 前 2 位数字为年份, 其次 3 位数字表示天数, 小数是不足 1 天的时间; .00038843 为轨道平动一阶导数; 00000-0 为轨道平动二阶导数; 11860-1 为大气阻力的弹道系数; 0 为轨道计算模型; 9997 为星历号.

第二行中 33773 为空间目标编号; 86.4001 为轨道倾角; 241.3039 为升交点赤经; 0013476 为轨道偏心率, 小数点在首位, 已省略; 118.3128 为近地点幅角; 241.9433 为平近点角; 14.41617791 为平均运动速度; 82192 为历元时刻圈数; 0 为校验和.

实验对 Space-Track 网站发布的铱星 33 碎片 TLE 数据进行训练, 实验数据列于表 1, 共包含 87 个铱星 33 空间碎片的连续 TLE 数据.

表 1 TLE 数据训练集
Table 1 TLE data training set

NORAD ID	Satname	Apogee/km	Perigee/km	Inclination/(°)	Period/min
33773	IRIDIUM33 DEB	757	742	86.40	99.82
33775	IRIDIUM33 DEB	765	747	86.37	99.95
⋮	⋮	⋮	⋮	⋮	⋮
40996	IRIDIUM33 DEB	627	607	86.35	97.04
46965	IRIDIUM33 DEB	713	683	86.33	98.73

* <https://www.space-track.org/>

1.2 数据预处理与 Savitzky-Golay 滤波参数平滑

根据对 TLE 轨道根数的特征提取, 将根数特征分为三类: 静态特征, 包括卫星编号、国际标识符、基准历元; 角度类特征, 包括轨道倾角 i 、升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0 ; 运动学特征, 包括平均运动 n 、偏心率 e 、大气阻力弹道系数 B' 以及平均运动一阶导数 $\dot{n}$. TLE 模型输入数据集由轨道要素字典 $\mathbf{X}(t)$ 构成, 其中包含角度类特征和运动学特征构成, 即

$$\mathbf{X}(t) = [i(t), \Omega(t), \omega(t), M_0(t), n(t), e(t), B'(t), \dot{n}(t)]^T. \quad (1)$$

式中, $i(t)$ 表示轨道倾角, $\Omega(t)$ 为升交点赤经, $\omega(t)$ 为近地点幅角, $M_0(t)$ 为平近点角, $n(t)$ 表示平均运动, $e(t)$ 为偏心率, $B'(t)$ 为大气阻力弹道系数, $\dot{n}(t)$ 为平均运动一阶导数.

为提高轨道参数序列拟合的准确性与 LSTM 神经网络模型的收敛性能, 从原始两行轨道根数文本中提取关键轨道要素, 包括倾角 i 、升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0 、平均运动 n 、偏心率 e 、平均运动一阶导数 $\dot{n}$ 和大气阻力弹道系数 B' , 并将角度类参数统一从弧度 (rad) 转换为角度单位 ($^\circ$).

针对轨道参数中的随机噪声与非平稳波动特性, 实验采用 Savitzky-Golay (SG) 平滑滤波器对偏心率 (e)、平均运动的一阶导数 ($\dot{n}$) 以及大气阻力弹道系数 (B') 参数进行平滑处理, 增强曲线拟合的稳定性. 该方法通过在局部滑动窗口内对数据点进行二阶多项式最小二乘拟合, 滤波窗口长度自适应, 最大不超过 101, 并用拟合曲线中心值替换原值, 形式如下:

$$\hat{y}_i = \sum_{j=-k}^k c_j \cdot y_{i+j}. \quad (2)$$

其中, $\hat{y}_i$ 为平滑后的数据点, y_{i+j} 表示原始数据在滑动窗口内的邻域值, c_j 为固定权重系数, 取决于多项式阶数与窗口长度.

在处理角度类轨道特征, 即升交点赤经 Ω 、近地点幅角 ω 和平近点角 M_0 时, 角度类轨道参数在 TLE 序列中具有周期性特性 ($0^\circ \sim 360^\circ$), 因为训练时长超过该空间碎片的运行周期, 在时间序列中可能出现跳变问题, 例如 359° 跳变至 1° , 真实变化是 $+2^\circ$, 但差值是 -358° , 拟合容易误判为剧烈变化, 因此需要对角度数据进行补偿.

针对此问题, 设计角度线性化展开策略, 将其变

换为连续单调序列, 确保后续回归模型的稳定训练和拟合, 将原始角度序列 θ_i 映射为连续展开的角度轨迹 $\tilde{\theta}_i$, 其递推形式如下.

设原始角度序列为 $\theta_1, \theta_2, \dots, \theta_n$, 定义线性化角度为 $\tilde{\theta}_i$, 有

$$\tilde{\theta} = \theta_0, \quad (3)$$

$$\tilde{\theta}_i = \tilde{\theta}_{i-1} + \text{mod_diff}(\theta_i, \theta_{i-1}), i = 1, 2, \dots, n. \quad (4)$$

式中, i 为角度序列的下标索引, 代表不同的时间步; t 可以视为真实的时间戳; n 为时间步总数; $\text{mod_diff}(\theta_i, \theta_{i-1})$ 为处理 $\pm 180^\circ$ 跳变的差值计算函数, 用于剔除周期性角度断裂, 实现角度参数的单调连续建模, 有

$$\text{mod_diff}(\theta_i, \theta_{i-1}) = \begin{cases} \theta_i - \theta_{i-1}, & |\theta_i - \theta_{i-1}| < 180^\circ; \\ \theta_i - \theta_{i-1} + 360^\circ, & \theta_i - \theta_{i-1} < -180^\circ; \\ \theta_i - \theta_{i-1} - 360^\circ, & \theta_i - \theta_{i-1} > 180^\circ. \end{cases} \quad (5)$$

参数拟合完成后, 还需要把线性化角度还原至 $0^\circ \sim 360^\circ$ 范围, 即

$$\theta_i^{\text{restored}} = \tilde{\theta}_i \bmod 360^\circ. \quad (6)$$

以 NORAD 编号 33773 目标为例, 对于近地点幅角 ω 和平近点角 M_0 数据, 调整前后拼接效果如图 1 所示.

在神经网络模型部分, 对平均运动 n 、偏心率 e 、平均运动一阶导数 $\dot{n}$ 、大气阻力弹道系数 B' 、倾角 i 这类复杂时间依赖性的轨道参数进行 Z-score 归一化处理, 通过计算均值和标准差将原始数据归一化为具有均值 0、标准差 1 的近似标准正态分布, 有效抑制异常值对模型性能的影响. 最终, 在模型输出阶段, 使用反归一化将拟合参数还原至原始物理量尺度, 确保模型输出的可解释性与工程可用性.

LSTM 模型输入前对目标序列 y_i 应用 Z-score 归一化处理, 其形式为

$$\tilde{y}_i = \frac{y_i - \mu}{\sigma}. \quad (7)$$

其中, $\tilde{y}_i$ 为归一化后的值; y_i 为原输入数据值; μ 为训练数据的均值; σ 为训练数据标准差.

归一化后的数据被用于 LSTM 模型训练, 每个样本是单一时间点的标准化轨道参数值, 与对应的时间戳一起作为独立输入提供给模型. 对于轨道参数序列 $\mathbf{Y}$ 和对应的时间序列 $\mathbf{X}$, 其输入形式为




图1 NORAD ID 33773 调整前后的拼接效果

Fig. 1 Stitching effect of NORAD ID 33773 before and after adjustment

$$\mathbf{X} = \{x_i\}_{i=1}^n \rightarrow \mathbf{Y} = \{y_i\}_{i=1}^n, x_i, y_i \in \mathbf{R}^{1 \times 1}. \quad (8)$$

式中, 时间序列输入 $\mathbf{X}$ 表示形状为 $[n, 1, 1]$ 的三维张量, 第一维为样本数 n , 第二维为时间步长为 1, 即每个样本只有一个时间点, 第三维为特征数为 1, 特征值仅为时间戳. 轨道参数序列输入 $\mathbf{Y}$ 的张量形状与 $\mathbf{X}$ 相同, 其第三维为归一化后的轨道参数值特征数量.

最终, LSTM 网络输出结果通过如下反归一化操作还原至原始尺度:

$$\hat{y}_i = \tilde{y}_i \times \sigma + \mu. \quad (9)$$

该处理流程将拟合结果还原为实际物理量, 其中 $\hat{y}_i$ 为反归一化后的参数值.

2 铱星 33 卫星碎片的 TLE 合成方法

在对铱星 33 碎片预处理后的连续 TLE 数据基础上, 构建了一套混合建模策略, 用于铱星 33 空间碎片 TLE 合成, 并说明了训练策略. 通过 LSTM 神经网络和多项式拟合混合建模方法处理不同特性的轨道参数, 即对具有复杂时间依赖性的参数采用 LSTM 模型拟合, 对具有周期性变化的角度参数采用多项式拟合.

2.1 构建 LSTM 模型

实验采用 LSTM 构建 TLE 参数的拟合模型. LSTM 引入门控机制, 其核心内容是遗忘门 (Forget Gate)、输入门 (Input Gate)、输出门 (Output Gate)

三个门控单元和记忆单元 (Memory Cell), 这些门控单元通过学习到的权重来控制信息的流动和保存^[16,17], 其网络结构如图 2 所示.

遗忘门通过 sigmoid 函数来选择性地遗忘上一个细胞状态中的信息, 其计算过程如下:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, \mathbf{x}_t] + b_f). \quad (10)$$

其中, f_t 表示遗忘门输出; $\mathbf{W}_f$ 和 b_f 分别表示遗忘门对应的权重矩阵与偏置项; $\mathbf{x}_t$ 表示当前时刻输入向量; h_{t-1} 表示上一时刻隐藏状态; σ 表示 Sigmoid 激活函数, 其输出数值范围在 0~1 之间. 遗忘门输出值用于控制上一时刻细胞状态 C_{t-1} 中信息的保留比例.

输入门通过 sigmoid 激活函数控制当前输入信息对细胞状态的更新程度, 其计算过程如下:

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, \mathbf{x}_t] + b_i). \quad (11)$$

其中, i_t 表示输入门输出; $\mathbf{W}_i$ 和 b_i 分别表示输入门对应的权重矩阵与偏置项. 输入门输出值用于决定当前输入信息写入细胞状态的比例.

候选细胞状态由当前输入 $\mathbf{x}_t$ 与上一时刻隐藏状态 h_{t-1} 共同生成, 其计算过程如下:

$$\tilde{c}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, \mathbf{x}_t] + b_c). \quad (12)$$

其中, $\tilde{c}_t$ 表示候选细胞状态; $\mathbf{W}_c$ 和 b_c 分别表示候选状态对应的权重矩阵与偏置项; $\tanh$ 表示双曲正切激活函数, 其输出数值范围为 -1~1.

遗忘门与输入门共同作用于细胞状态, 实现历史

信息保留与当前信息更新, 其更新过程如下:

$$C_t = f_t * C_{t-1} + i_t * \tilde{c}_t. \quad (13)$$

其中, $*$ 表示逐元素相乘; C_t 表示当前时刻细胞状态; C_{t-1} 表示上一时刻细胞状态, C_t 为 C_{t-1} 更新状态.

输出门决定当前细胞状态的输出程度, 其计算过程如下:

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, \mathbf{x}_t] + b_o). \quad (14)$$

其中, o_t 表示输出门输出; $\mathbf{W}_o$ 和 b_o 分别表示候选状态对应的权重矩阵与偏置项.

最终, 隐藏状态由输出门与当前细胞状态共同决定, 其计算过程如下:




图2 LSTM网络结构

Fig. 2 LSTM network structure

$$h_t = o_t * \tanh(C_t). \quad (15)$$

其中, h_t 表示当前时刻隐藏状态.

实验所使用 TensorFlow 序列模型由五层堆叠式 LSTM 网络层与两层全连接神经网络 (Dense) 组成. 模型结构如图3所示.

该模型结构主要用于拟合复杂时间依赖性的轨道参数 (平均运动 n 、偏心率 e 、平均运动一阶导数 $\dot{n}$ 、大气阻力弹道系数 B' 、倾角 i). 每个样本是单一时间点的标准化轨道参数值, 与对应的时间戳一起作为独立输入提供给模型. 原始轨道参数值 y_i 经 Z-score 归一化处理, 如式 (7) 所示. 模型采用 5 个堆叠的 LSTM 层和 2 个全连接 Dense 层, 前四层 LSTM 层均设置为 `return_sequences=True`, 模型返回序列中每个时间步的输出, 以传递完整的序列特征至下一层; 最后一层 LSTM 层输出最终时间步的隐藏状态, 作为全连接层 Dense 输入并进行拟合, 最终将输出结果通过式 (9) 的逆归一化操作还原至原始尺度.

训练过程中, 使用平均绝对误差 MAE (Mean Absolute Error, 定义符号 δ_{MAE}) 作为损失函数, 用于优化模型的评价指标, 兼顾精度与抗异常能力, 有

$$\delta_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |O_{\text{pred}, i} - O_{\text{true}, i}|. \quad (16)$$




图3 TensorFlow序列模型

Fig. 3 TensorFlow sequential models

模型中采用 Adamax 优化器, 模型训练轮数设置为 150, 批量大小为 32, 训练过程中不启用 EarlyStopping, 所有训练过程在图形处理器 (GPU) 上运行.

2.2 构建多项式拟合模型

在 TLE 轨道要素中, 角度类参数如升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0 , 有显著的周期性变化特征, 实验选择使用多项式拟合方法对这些参数进行建模. 多项式拟合通过使用一组高阶多项式来近似角度参数的时序数据. 相比传统的线性回归方法, 多项式拟合能够更好地捕捉角度数据中的周期性变化和非线性特征, 特别是对于角度类数据的周期性跳变 (例如 359° 跳变至 1°) 提供了良好的平滑效果. 采用 n 阶多项式拟合来近似角度类参数 $y(t)$, 有

$$y(t) = \sum_{i=0}^n a_i t^i. \quad (17)$$

其中, $y(t)$ 为轨道角度参数的输入, t 为时间戳; a_i 为多项式系数, 通过最小二乘法计算得到; n 为多项式的阶数.

为充分捕捉角度类参数的周期性变化, 并避免过拟合, 多项式阶数 n 依据实验经验与拟合效果选择最佳阶数 8 阶多项式作为升交点赤经拟合函数, 近地点幅角和平近点角采用 7 阶多项式. 使用最小二乘法以及适当的初始猜测进行系数 a_i 的优化, 最小化拟合值与真实值之间的误差.

2.3 训练策略

对于训练策略, 采用混合建模策略, 对升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0 使用多项式拟合, 轨道倾角 i 、平均运动 n 、偏心率 e 、大气阻力弹道系数 B' 以及平均运动一阶导数 $\dot{n}$ 使用 LSTM 模型. 实验完整方法如图 4 所示.

数据预处理阶段包括数据收集和过滤, 从 TLE 文件中提取卫星轨道参数, 解析 TLE 文件以提取关键轨道参数, 根据训练时间范围过滤 TLE 记录, 将儒略日期转换为相对时间值, 方便进行时间序列分析; 角度参数标准化, 轨道角参数升交点赤经、近地点幅角和平近点角存在周期性以及 $0^\circ/360^\circ$ 边界处的不连续性, 为解决这个问题, 对于递增角度的序列通过增加 360° 来调整明显减小的值, 以保持连续性, 递减角度序列反之, 这些调整创建了适合函数逼近和机器学习的连续轨迹; 轨道参数平滑, 为减少测量噪声并提高模型稳定性, 对选定的轨道参数偏心率 e 、平均运动的一阶导数 $\dot{n}$ 以及大气阻力弹道系数 B' 应用 Savitzky-Golay 滤波平滑参数, 在消除高频噪声的同时保留主要特征, 并根据可用数据点自适应选择窗口长度和多项式阶数; 神经网络训练的数据规范化, 在将轨道参数输入到 LSTM 模型之前, 进行 Z-score 标准化, 以确保数据尺度统一, 提高模型收敛性和准确性.

在模型构建时, 将输入模型的轨道参数分为: 复




图 4 TLE 轨道合成流程

Fig. 4 Flowchart of TLE orbit synthesis process

杂时间依赖性的参数 (平均运动的一阶导数 $\dot{n}$ 、大气阻力弹道系数 B' 、平均运动 n 、轨道倾角 i 和偏心率 e), 用于 LSTM 网络训练; 具有更规则、确定性演变模式的参数 (升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0), 采用多项式回归进行参数拟合. 这里采用的建模方式为输入-输出时间对齐型拟合. 具体而言, 输入序列为完整轨道参数序列中除去最后 n 个时间步的部分, 输出为同一轨道参数序列在时间上整体向后平移 n 步的对应值. 通过对轨道参数序列进行整体处理, 将其输入输出在时间维度上严格对齐, 在时间维度上实现拟合-验证的耦合性.

在轨道参数拟合最后阶段, 根据拟合参数合成完整的 TLE 数据, 合成过程包括: 将拟合的升交点赤经 Ω 、近地点幅角 ω 、平近点角 M_0 连续角度值转换回 $0^\circ \sim 360^\circ$ 范围, 平均运动 n 、偏心率 e 、平均运动一阶导数 $\dot{n}$ 、大气阻力弹道系数 B' 、轨道倾角 i , 根据 TLE 规范格式化参数, 并使用 SGP4 传播器验证合成 TLE 的有效性.

3 铱星 33 碎片 TLE 合成结果与分析

3.1 轨道传播误差对比分析

在对铱星 33 产生的 87 个空间碎片进行的 TLE 高精度合成实验中, 针对 2024 年 7 月 1 日至 11 月

21 日轨道未产生衰减的铱星 33 空间碎片连续 TLE 数据进行处理, 合成日期为 2024 年 11 月 22—25 日, 合成时段内共 5 个目标 Space-Track 网站未公布数据, 剔除这 5 个目标, 利用 SGP4 传播器分别对合成的 TLE 与合成时段内 81 个铱星 33 空间碎片原始轨道进行 7 天正向传播, 并与参考轨道对比位置误差.

实验过程中, 目标 33966, 35911, 38017 拟合结果出现极端异常. 虽然这些数据已纳入统计分析, 考虑到其异常特征, 为提高图表可读性, 在后续的图表分析中对其给予隐藏显示.

图 5 给出了铱星 33 产生的 81 个空间碎片轨道位置误差分析三维柱状结果. 结果显示, 随着合成时长增加, 原始 TLE 和合成 TLE 传播误差都逐渐累积增大, 第 3 天部分目标表现出较大系统性误差, 例如 NORAD ID35484 原始 TLE 数据传播误差随传播时长增加, 传播至第 3 天时, 位置误差超过 100 km, 突增至 145.285 km, 37550 原始 TLE 数据位置误差传播 3 天内均超过 350 km, 传播至第 3 天时, 位置误差约 492.155 km, 表明可能存在轨道力学模型参数或初始状态矢量估计方面的系统偏差. 其余空间目标原始轨道误差有几个明显的峰值, 误差范围为 40~150 km, 整体数据呈现明显的非均质性, 部分空间目标在修正后均表现出一天内的传播误差有较大位置偏差, 改善效果并不明显. 图 5 中可观察到合成算法




图 5 81 个铱星 33 碎片位置误差三维柱状结果

Fig. 5 3D position error bar of 81 fragments from Iridium 33

对大部分空间碎片目标的误差有显著降低效果, 尤其是在传播天数为 2 和 3 时。

图 6 给出了 7 个时间点的铱星 33 空间碎片

误差对比的柱状结果, 7 个子图分别反映了不同时间点上 TLE 的传播误差比较。第 1 天时可观察到 NORAD ID35484 和 36483 的原始 TLE 误差分别达



图 6 81 个铱星 33 碎片传播 7 天位置误差对比的柱状结果

Fig. 6 Bar chart comparison of the 81 Iridium 33 fragments position errors over seven-day propagation

约 59.056 km 和 33.651 km, 属于极端异常值, 合成后误差分别为 10.078 km 和 8.067 km. 其中 25 个目标第 1 天传播误差未得到改善, 其余空间目标合成 TLE 后表现出较小误差, 多数空间目标合成后的 TLE 误差显著降低, 传播误差改善的碎片占比约达碎片总数的 69.14%. 第 2 天的误差演变相比第 1 天, 绝大多数卫星的原始 TLE 误差增大, 其中 33887 的原始 TLE 误差突降至 75 m, 该目标合成后的 TLE 与原始 TLE 有极大偏差, 37550 的原始 TLE 与合成 TLE 仍保持较大的误差, 但该目标的合成 TLE 已明显小于原始 TLE 的位置误差. 第 2 天时合成 TLE 在多数碎片上继续保持低误差水平, 相比第 1 天, 合成 TLE 的修正效果有所减弱, 但是误差改善的目标占比增多, 共 10 个目标未得到改善, 传播误差改善的碎片占比约达碎片总数的 87.65%. 第 3 天误差进一步演变, 原始 TLE 误差普遍进一步增大, 大部分合成 TLE 的位置误差逐渐收敛, 趋近于稳定; 11 个目标第 3 天的传播误差未得到改善, 传播误差改善的碎片占比约达碎片总数的 86.42%. 第 4—7 天, 33850, 35628 和 39777 的合成 TLE 拟合效果偏差较为显著, 其余空间目标 TLE 误差随传播时间逐步增大. 第 4 天时 9 个目标的位置传播误差未得到改善, 传播误差改善的碎片占比约达碎片总数的 88.89%. 14 个目标在第 5 天的位置传播误差未得到改善, 传播误差改善的碎片占比约达碎片总数的 82.72%. 随着传播时间的增长, 误差改善效果呈现进一步衰减态势, 第 6 天时传播误差改善目标占比降至 70.37%, 共 24 个目标未得到改善. 至第 7 天时未得到改善的目标共 28 个, 改善目标占比下滑至 65.43%.

表 2 统计结果显示, 传播误差改善率呈现波动下降的总体趋势: 第 1 天改善目标占比为 69.14%, 未改善目标 25 个; 第 2—4 天改善效果相对较好, 改善率分别达到 87.65%, 86.42% 和 88.89%, 未改善目标数量维持在 9~11 的较低水平; 第 5 天开始出现下滑, 改善率降至 82.72%; 第 6—7 天改善效果进一步恶化, 改善率分别下降至 70.37% 和 65.43%, 未改善目标数量激增至 24 和 28.

图 7 以中位数/四分位数/范围形式, 对比了 7 个时间点上原始 TLE (蓝绿色) 与合成 TLE (粉红色) 传播 7 天的位置误差分布特征. 图 7 显示合成 TLE 的误差分布明显更为集中, 合成 TLE 在 7 个时间点的

位置误差中位数分别为 535.5, 404, 634, 996.5, 3863.5, 17640.5, 46685.5 m, 原始 TLE 在 7 个时间点的位置误差中位数分别为 2072.5, 5045.5, 9643, 16791, 28792.5, 48245, 67808 m, 合成 TLE 在 7 个时间点的中位数均显著低于原始 TLE, 体现出更强的传播稳定性, 但是误差也随着传播时间增加而逐渐增大, 第 5 天以后呈现较快上升趋势. 从四分位间距 (Q1~Q3) 来看, 合成 TLE 的误差分布更加集中, 7 个时间点的 IQR 分别为 6554, 2355, 4142, 3413, 23396, 58040, 107439 m, 除第 1 个时间点外, 其余均小于原始 TLE 对应的 4991, 9550, 20986, 32415, 49845, 78209, 119961 m, 说明合成 TLE 具有更好的稳定性. 但是至第 7 天时, 合成 TLE 的 IQR 升高至 107439 m, 表明误差波动范围显著扩大, 与原始 TLE 的 119961 m 接近, 其误差控制能力衰减. 合成 TLE 在 4 天内位置误差传播展现出较强的误差压制能力和稳定性.

图 8 显示的是一个三维曲面. 图 8 通过红色 (合

表 2 81 个铱星 33 碎片 TLE 7 天传播误差改善效果统计
Table 2 Statistic of improvement effect on seven-day propagation error of 81 Iridium 33 fragments

Time/d	Proportion of improved cases/(%)	Number of unimproved items
1	69.14	25
2	87.65	10
3	86.42	11
4	88.89	9
5	82.72	14
6	70.37	24
7	65.43	28




图 7 81 个铱星 33 碎片传播误差箱线结果对比
Fig. 7 Boxplot comparison of the propagation errors of 81 Iridium 33 fragments

成 TLE) 和粉色 (原始 TLE) 区域显示了误差分布, 可观察到合成后的 TLE (深红色区域) 在多数空间目标上传播误差明显降低, 但是仍有局部峰值存在, 表明少部分卫星合成后的修正效果仍存在较大误差。

图 9 和图 10 给出了原始 TLE 和合成 TLE 利用 SGP4 传播器传播 3 天误差的传播误差频率分布。为显示图表的直观性, 统计了误差分布范围为 0~




图 8 81 个铱星 33 碎片误差变化三维瀑布结果

Fig. 8 3D waterfall plot of the error changes of 81 Iridium 33 fragments

20 km 的频率分布。合成 TLE 在 3 天内的传播误差均集中于 0~2 km 区间, 3 天内 0~2 km 分布频率分别为 75.00%, 74.67%, 66.22%, 其中 3 天内误差分布在 200~400 m 区间的频率分别为 54.41%, 52.00%, 48.65%, 原始 TLE 在 3 天内传播误差为 0~2 km 的分布频率分别为 50.67%, 31.82% 和 18.97%, 合成 TLE 的传播误差较为集中, 误差范围较小, 随合成时长增长, 误差分布较稳定, 原始 TLE 传播误差随合成时长增长误差范围逐渐扩散, 受误差累积影响较大, 未出现显著集中, 且误差分布更为分散。合成 TLE 传播误差在 5 km 以上样本占比极少, 整体分布更为集中, 原始 TLE 传播误差尾部较长, 表明其数据存在不稳定性。合成 TLE 传播误差大量误差集中在低值区, 少量异常值构成长尾, 原始 TLE 的传播误差分布更接近于宽峰重尾, 存在一定的多峰趋势。

图 11 给出了 1.1 节所提目标 33773 在磁暴期间 (2024 年 10 月 11 日 10:18 UT) 原始 TLE 与合成 TLE 分别利用 SGP4 传播的 7 天位置误差, 进一步验证 LSTM 模型的性能。该时刻合成 TLE 如下。

```
1      33773U      97051L      24285.42931793
      .00000000      00000-0      91376-3      0      9995
```




图 9 81 个铱星 33 碎片原始 TLE 3 天传播误差频率分布

Fig. 9 Distribution of original TLE 3-day propagation error frequencies for 81 Iridium 33 fragments




图 10 81 个铱星 33 碎片合成 TLE 3 天传播误差频率分布

Fig. 10 Distribution of synthetic TLE 3-day propagation error frequencies for 81 Iridium 33 fragments

2 33773 86.4001 241.3039 0013503
118.3128 241.9433 14.41575799 5563 6

不同空间对象的数据量不同, 分割后的实际数据大小也不同. 训练数据量对预测效果的影响已在文献 [18] 中讨论过.

3.2 太阳活动对轨道合成精度的影响

实验时间段正值第 25 太阳活动周的上升期向峰值过渡阶段. 据中国气象局国家空间天气监测预警中心 2024 年 10 月 11 日发布的信息, 受日冕物质抛射影响, 2024 年 10 月 10 日 23:00 LT 至 11 日 17:00 LT, 地球连续发生 18 h 的特大磁暴活动, K_p 指数最大值达到 8.67. 该事件正发生在本文 TLE 数据训练期间, 对此针对铱星 33 空间碎片连续 TLE 数据进行处理, 合成日期范围为 2024 年 10 月 10 日 23:00 LT 至 11 日 17:00 LT. 由于 22 个目标在合成日期范围内 Space-Track 网站并未公布 TLE 数据, 因此需要剔除, 对剩余 65 个铱星 33 空间碎片进行磁暴期间的轨道合成精度分析, 对合成时段内 65 个铱星 33 空间碎片的原始 TLE 和合成 TLE 分别使用 SGP4 传播器正向传播 3 天位置误差.




图 11 目标 33773 传播 7 天的误差对比

Fig. 11 Comparison of the propagation errors for Target 33773 over 7 days




图 12 65 个铱星 33 碎片传播三天位置误差的柱状结果对比

Fig. 12 Bar chart comparison of the position errors of 65 Iridium 33 fragments propagated over three days

图 12 给出了 65 个铱星 33 碎片磁暴期间原始 TLE 与合成 TLE 传播 3 天的位置误差柱状结果对比, 目标 34492 和 34775 的合成 TLE 在 3 天内传播的位置误差均远大于原始 TLE, 属于异常极端值, 3 个时间点的传播误差改善目标占比分别为 80.00%, 78.46% 和 70.77%.

图 13 以中位数/四分位数/范围的箱线图形式, 直观对比了磁暴期间原始 TLE (蓝绿色) 与合成 TLE (粉红色) 的传播 3 天位置误差的分布特征. 合成 TLE 与原始 TLE 3 个时间点的位置误差中位数分别为 1088, 5348, 10894 m 和 8589, 18663, 33408 m. 三个时间点内合成 TLE 与原始 TLE 传播的位置误差四分位间距 ($Q_1 \sim Q_3$) 分别为 6117, 13651, 27260 m 和 14805, 47065, 70340 m. 合成 TLE 在 3 个时间点内的位置误差中位数和四分位间距均小于原始 TLE.

对比常规时段, 磁暴时段内原始 TLE 和合成 TLE 传播误差均出现增大, 误差波动范围也同步扩大. 在强太阳活动背景下, 空间环境扰动加剧, SGP4 模型传播精度受误差的非线性累积而加强. 相比常规时段, 磁暴期间 3 天内的改善目标占比除第 1 天优于常规时段外, 其余改善目标占比均小幅下降, 但是合成 TLE 在 3 个时间点的误差中位数和四分位间距始终显著小于原始 TLE, 显示出更强的稳定性与抗干扰能力.

4 结论

利用 TLE 数据进行空间目标轨道预测与跟踪、空间态势感知至关重要. 提出一种基于 LSTM 神经网络的 TLE 高精度轨道合成方法, 针对铱星 33 空间碎




图 13 65 个铱星 33 碎片传播误差箱线结果对比

Fig. 13 Boxplot comparison of the propagation errors of 65 Iridium 33 fragments

片的轨道合成进行系统研究, 在提升空间态势感知能力、轨道碰撞预警和任务调度方面具有一定应用价值.

实验预处理设计的角度线性化展开策略有效解决了周期性变化的角度类轨道参数 (升交点赤经、近地点幅角和平近点角) 的周期性跳变问题, 确保角度参数的拟合连续性, 为后续模型提供了稳定可靠的输入. Savitzky-Golay 平滑滤波对易受噪声影响的参数 (偏心率、平均运动一阶导数以及大气阻力弹道系数) 进行平滑处理, 增强拟合稳定性. 基于 LSTM 神经网络与多项式拟合相结合的混合建模策略能够有效捕捉 TLE 轨道要素的复杂时间演化特性. 对于有显著周期性变化的角度类参数 (升交点赤经、近地点幅角、平近点角), 采用多项式拟合提供了良好的拟合效果; 对于非线性变化的参数 (平均运动、偏心率、平均运动一阶导数、大气阻力弹道系数、倾角), LSTM 模型表现出优异的拟合能力.

实验表明, 在常规时段下合成 TLE 相比原始 TLE 有显著提升, 81 个铱星碎片合成 TLE 在 7 天的位置传播误差改善目标占比分别为 69.14%, 87.65%, 86.42%, 88.89%, 82.72%, 70.37% 和 65.43%, 并且误差分布集中稳定. 在强太阳活动时段下, 65 个铱星 33 碎片 3 天位置误差改善目标占比分别为 80.00%, 78.46% 和 70.77%, 在强太阳活动背景下, 合成 TLE 相比原始 TLE 仍表现出更低的误差波动范围.

原始 TLE 非实时连续采集, 更新频率不恒定, 观测数据质量有限以及模型扰动简化等因素导致误差迅速积累, 造成显著偏离真实轨道. 本文提出了基于 LSTM 神经网络和多项式混合建模策略的 TLE 高精度轨道合成方法, 对于解决上述问题展现出明显优势, 提升了 TLE 数据的轨道预报的准确性.


利益冲突 所有作者均声明不存在利益冲突.

参考文献

- [1] THAMMAWICHAI M, LUANGWILAI T. Data-driven satellite orbit prediction using two-line elements[J]. *Astronomy and Computing*, 2024, **46**: 100782
- [2] WANG Zhen, JI Yimin, BAI Guoqing, *et al.* Research on the enhancement strategies for the space debris handling capabilities of China space station[J]. *Aerospace Shanghai (Chinese & English)*, 2025, **42**(3): 26-31 (王震, 季逸民, 白国庆, 等. 我国空间站应对空间碎片能力提升方案研究 [J]. *上海航天 (中英文)*, 2025, **42**(3): 26-31)
- [3] LEI Xiangxu, XIA Shengfu, LIU Hongkang, *et al.* Analysis of the first space debris collision avoidance event of Galileo satellite[C]//Proceedings of the 14th China Satellite Navigation Annual Conference. Jinan: Academic Exchange Center of China Satellite Navigation System Management Office, 2024: 50-56 (雷祥旭, 夏胜夫, 刘宏康, 等. 伽利略卫星首次轨道机动规避空间碎片事件分析 [C]//第十四届中国卫星导航年会论文集——S03 卫星轨道与精密定位. 济南: 中国卫星导航系统管理办公室学术交流中心, 2024: 50-56)
- [4] LIU Qi, MAO Wei, HU Peng, *et al.* Application and development of high-precision Hall electric propulsion technology[J]. *Chinese Space Science and Technology*, 2023, **43**(2): 1-15 (刘祺, 毛威, 胡鹏, 等. 高精度霍尔电推进技术的应用与发展研究 [J]. *中国空间科学技术*, 2023, **43**(2): 1-15)
- [5] JIA Q L, XIAO J P, BAI L, *et al.* Space situational awareness systems: bridging traditional methods and artificial intelligence[J]. *Acta Astronautica*, 2025, **228**: 321-330
- [6] ACCIARINI G, BAYDIN A G, IZZO D. Closing the gap between SGP4 and high-precision propagation via differentiable programming[J]. *Acta Astronautica*, 2025, **226**: 694-701
- [7] 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
- [8] CHANG S Y, WU H C, SOTIROPOULOS F, *et al.* Robust satellite-orbit prediction using artificial neural network based on Levenberg-Marquardt algorithm[C]//2022 International Wireless Communications and Mobile Computing (IWCMC). Dubrovnik, Croatia: IEEE, 2022: 1329-1334
- [9] LU Ruiying. Research on Deep Dynamic Generative Model for Learning Feature from Sequential Data[D]. Xi'an: Xidian University, 2022 (鲁瑞颖. 面向序列数据特征学习的深度动态生成模型构建方法研究 [D]. 西安: 西安电子科技大学, 2022)
- [10] OSAMA A, RAAFAT M, DARWISH A, *et al.* Satellite orbit prediction based on recurrent neural network using two line elements[C]//2022 5th International Conference on Computing and Informatics (ICCI). New Cairo, Cairo,

- Egypt: IEEE, 2022: 298-302
- [11] DRÁČEK F, ĐURIKOVIĆ R, ŠILHA J. Validation of unsupervised anomaly detection from historical satellite positional data[C]//2024 28th International Conference Information Visualisation (IV). Coimbra, Portugal: IEEE, 2024: 1-5
- [12] Li H G, LIU Y Q, SHI J L, *et al.* Multimodal LSTM forecasting for LEO satellite communication terminal access[C]//2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring). Florence, Italy: IEEE, 2023: 1-5
- [13] PAN Xiong, HUANG Weikai, WANG Cong, *et al.* BDS-3 clock error short-term prediction algorithm based on semi-parametric-varying-coefficient-SVM combined model[J]. *Geomatics and Information Science of Wuhan University*, 2024: 1-13 (潘雄, 黄伟凯, 王聪, 等. 半参数变系数与支持向量机组合模型的 BDS-3 钟差短期预报算法研究 [J]. 武汉大学学报 (信息科学版), 2024: 1-13)
- [14] GONG Baichun, LI Shuang, ZHENG Lili, *et al.* Angles-only relative navigation algorithm for close-in proximity of space non-cooperative target[J]. *Journal of Chinese Inertial Technology*, 2018, **26**(2): 173-179 (龚柏春, 李爽, 郑莉莉, 等. 空间非合作目标近程交会仅测角相对导航方法 [J]. 中国惯性技术学报, 2018, **26**(2): 173-179)
- [15] TANG Jingshi, CHENG Haowen. The origin, status and future of space debris[J]. *Physics*, 2021, **50**(5): 317-323 (汤靖师, 程昊文. 空间碎片问题的起源、现状和发展 [J]. 物理, 2021, **50**(5): 317-323)
- [16] ZHANG Xinyu, LIU Yuan, SONG Jianing. Short-term orbit prediction based on LSTM neural network[J]. *Systems Engineering and Electronics*, 2022, **44**(3): 939-947 (张心宇, 刘源, 宋佳凝. 基于 LSTM 神经网络的短期轨道预报 [J]. 系统工程与电子技术, 2022, **44**(3): 939-947)
- [17] HE Xinran, ZHONG Qiuzhen, CUI Yanmei, *et al.* Solar flare short-term forecast model based on long and short-term memory neural network[J]. *Chinese Journal of Space Science*, 2022, **42**(5): 862-872 (何欣燃, 钟秋珍, 崔延美, 等. 基于长短期记忆神经网络的太阳耀斑短期预报 [J]. 空间科学学报, 2022, **42**(5): 862-872)
- [18] Lin C S, Chen J Y. Using long short-term memory neural network for satellite orbit prediction based on two-line element data[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2025, **61**: 1-10

作者简介



胡开辉 男, 2002 年 12 月出生于云南省曲靖市, 现为昆明理工大学国土资源工程学院在读硕士研究生, 主要研究方向为利用深度学习的太空目标轨道预报精度优化方法。

E-mail: 20242201139@stu.kust.edu.cn



陈俊宇 男, 1989 年 1 月出生于云南省大理市, 现为昆明理工大学国土资源工程学院讲师, 硕士研究生导师, 主要研究方向为空间态势感知。

E-mail: jychen@kust.edu.cn