



引文格式:唐宇,张伟,李星星,等.基于机器学习的低轨卫星高精度轨道预报[J].武汉大学学报(信息科学版),2025,50(11):2373-2380.DOI:10.13203/j.whugis20230411

Citation: TANG Yu, ZHANG Wei, LI Xingxing, et al. High-Accuracy Orbit Prediction of Low Earth Orbit Satellites Using Machine Learning Algorithms[J]. Geomatics and Information Science of Wuhan University, 2025, 50(11): 2373-2380. DOI: 10.13203/j.whugis20230411

基于机器学习的低轨卫星高精度轨道预报

唐宇¹ 张伟¹ 李星星¹ 付元辰¹ 张柯柯¹

¹ 武汉大学测绘学院, 湖北 武汉, 430079

摘要: 高精度低轨卫星预报轨道是全球低轨导航增强应用的基础。目前应用较为广泛的动力学外推方法存在着受动力学模型精度影响大、预报误差累积快的问题。为弥补这一缺陷,将机器学习方法与动力学外推法结合以提升低轨卫星轨道预报精度,并对支持向量机(support vector machine, SVM)、反向传播(back propagation, BP)神经网络和长短期记忆(long short term memory, LSTM)神经网络3种机器学习方法在低轨卫星轨道预报中的适用性进行了深入分析。利用Sentinel-3A卫星2019-01-01—2019-07-14的数据集进行了预报时长为180 min的短期轨道预报实验,对模型最优参数进行了探究,基于各模型最优参数配置进行轨道预报实验。结果表明,3种机器学习方法均能有效提升低轨卫星轨道预报精度,提升效果在不同预报时长下存在明显差异。当轨道预报时间为20 min, LSTM神经网络模型对预报轨道的精度提升效果(38.1%)显著优于SVM(-0.1%)与BP(-1.2%),预报轨道精度可达1.07 cm(3D)。当预报时长大于40 min, SVM和BP模型的效果优于LSTM模型。在预报时长达到180 min时, SVM和BP模型仍可以实现6~7 cm的轨道预报精度,相比于传统动力学法提升了约50%。

关键词: 轨道预报;机器学习;神经网络;低轨卫星

中图分类号: P228

文献标识码: A

收稿日期: 2024-05-28

DOI: 10.13203/j.whugis20230411

文章编号: 1671-8860(2025)11-2373-08

High-Accuracy Orbit Prediction of Low Earth Orbit Satellites Using Machine Learning Algorithms

TANG Yu¹ ZHANG Wei¹ LI Xingxing¹ FU Yuanchen¹ ZHANG Keke¹

¹ School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China

Abstract: Objectives: Precise orbit prediction of low earth orbit (LEO) satellites is the foundation of LEO augmentation navigation. Due to the impact of non-conservative perturbation forces, conventional dynamic extrapolation method relies on high-accuracy dynamic models and suffer from rapid error accumulation. **Methods:** We combine machine learning algorithms and dynamic integration method to improve the accuracy of LEO orbit prediction. Three machine learning models are analyzed, including support vector machine (SVM), back propagation (BP) and long short term memory (LSTM) neural networks. To compare the performance of different machine learning algorithms in the high-accuracy orbit prediction, we process the orbit error time series of Sentinel-3A from January 1 to July 14, 2019, with the dynamic features selected by extreme gradient boosting (XGBoost). The optimal input configuration parameters for each machine learning models are further investigated to exploit the potential of the models in the orbit prediction. **Results:** The result shows that the performance of three machine learning models in the prediction varies from prediction time. When the prediction time is limited to 20 min, LSTM model presents the best performance with an accuracy improvement of 38.1%, which is evidently superior to SVM (-0.1%) and BP (-1.2%), and the corresponding orbit accuracy is 1.07 cm (3D). For the prediction exceeding 40 min, SVM and BP models

基金项目:国家重点研发计划(2021YFB2501102)。

第一作者:唐宇,硕士生,研究方向为低轨卫星精密定轨。ytangSGG@whu.edu.cn

通信作者:李星星,博士,教授。xxli@sgg.whu.edu.cn

outperform LSTM. When the prediction time reaches 180 min, the predicted orbit can still achieve the accuracy around 6–7 cm with the employment of SVM/BP models. **Conclusion:** Three models can effectively improve the orbit prediction accuracy of LEO satellites. LSTM model can achieve the best performance in ultra-short prediction (20 min), while SVM and BP models are more suited to the prediction exceeding 40 min. Compared with the traditional orbit prediction method, the improvement of machine learning models is about 40%–50% overall.

Key words: orbit prediction; machine learning; neural network; low earth orbit satellite

近年来,低地球轨道(low earth orbit, LEO)卫星任务蓬勃发展。与中/高轨卫星相比,低轨卫星具有几何观测构型变化快、信号强度高等特点,在导航定位领域具有较强的应用潜力,因此部分学者提出建立低轨导航星座的构想,利用低轨卫星播发导航信号来实现对全球导航卫星系统(global navigation satellite system, GNSS)的增强^[1-5]。为实现低轨导航增强目标,低轨卫星需要向地面用户实时播发低轨卫星星历,提供准确的低轨卫星时空信息。由于卫星信号从播发到用户接收的过程存在时延,考虑到用户对实时性的需求,需要进行轨道预报以生成相应的低轨卫星星历。因此,低轨卫星高精度轨道预报是低轨导航增强应用的基础与前提,直接决定着导航增强的服务性能。

动力学外推法是目前应用最为广泛的高精度轨道预报方法,该方法利用卫星的初始轨道与建立的摄动力模型进行轨道积分外推^[6],可在理论上取得较高的预报精度。但低轨卫星受大气阻力、太阳光压等非保守摄动力模型精度影响大,轨道精度衰减快,仅50 min时长外推轨道的切向误差可超过40 cm^[7]。在这种情况下,为满足低轨导航增强应用中对厘米级实时轨道的要求,低轨卫星需要频繁地预报并播发星历,这将会极大地增加低轨星座系统运行的复杂度与运维成本,限制低轨导航增强系统的性能。

近年来,部分学者将机器学习方法应用于卫星动力学轨道预报,以提升卫星的轨道预报精度。机器学习能够直接对非线性模型的数据进行学习及拟合,不需要额外建立物理模型,模型训练完成后不会带来大的计算负荷。PENG等^[8-9]使用支持向量机(support vector machine, SVM)以及人工神经网络(artificial neural network, ANN)对传统预报方法的预报误差进行了学习,在7 d预报中的位置残差小于1 km。曹磊^[10]建立了基于深度神经网络的补偿混合模型,采用反向传播(back propagation, BP)神经网络对全球定位系统(global positioning system, GPS)卫

星的预报误差长期发散项进行补偿,预报5 d的最大误差为8.58 m。杨先睿^[11]采用长短期记忆(long short term memory, LSTM)神经网络直接对卫星坐标进行了预测,通过仿真验证了模型的可行性,但预测精度有待提升。张心宇等^[12]选取位置、速度、加速度为特征输入LSTM模型,对SGP4(simplified general perturbations)解析法预报轨道模型的历史误差进行了学习,预报400 min的最大残余误差在50 m左右。已有研究证明了SVM、BP、LSTM模型在轨道预报应用上的可行性,对于不同的卫星和预报时长,不同机器学习模型性能存在差异。但已有研究大多更关注一天至数十天的轨道预报,且对绝对轨道精度要求不高。而在低轨导航增强应用中更关注高精度的短期轨道预报(数十分钟至数小时)。针对该需求,本文将卫星轨道预报中常用的3种机器学习模型——SVM、BP及LSTM神经网络应用于低轨卫星短期轨道预报(3 h以内),探究不同机器学习模型在短期轨道预报上的性能差异,以提高轨道预报精度,降低低轨卫星更新星历的频率,提升低轨导航增强服务性能。首先介绍了使用的机器学习模型及其应用于低轨卫星轨道预报中的实现方法;然后对训练所用低轨卫星数据集进行了阐述,在此基础上,介绍了数据预处理和机器学习模型配置;最后对比分析了不同机器学习模型在不同预报时长下对预报轨道精度的改善效果,并通过轨道精度等指标评估了模型性能。

1 基于机器学习的低轨卫星轨道预报方法

1.1 机器学习模型

SVM是基于结构风险最小的一种样本监督学习算法。其引入核函数映射方法,将输入向量映射到高维空间,从而把原空间的非线性分类问题转换为线性凸二次规划问题^[13]。

BP神经网络由RUMELHART等^[14]在1986

年首次提出。其特点为正向传播数据,对于误差采取BP算法调整网络。BP神经网络的每层均由若干个神经元组成,数据带着权重在每层神经元间传递,到达输出层得到输出,随后误差进行反向传播,不断调整权重优化结果,最终得到训练好的网络^[15]。

LSTM神经网络最初由HOCHREITER等^[16]提出,它是一种循环神经网络,能够解决传统神经网络中梯度消失或爆炸的问题,对有长期或短期依赖的数据进行精确建模^[17]。

1.2 机器学习结合动力学积分

动力学积分考虑到多种摄动力对于低轨卫星轨道的影响,涉及到大量相关特征。机器学习可以结合动力学积分的相关特征,对轨道预报误差进行建模,并对原有的预报结果进行修正,以提高轨道预报的精度。机器学习结合动力学积分的整体处理流程如图1所示,处理过程主要分为三部分:数据获取、预处理和模型预测及修正。

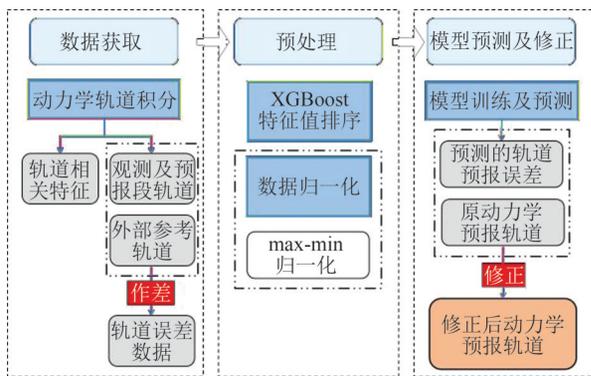


图1 机器学习结合动力学轨道预报的处理流程

Fig. 1 Processing Flow of Dynamical Orbit Prediction Combined with Machine Learning

1)数据获取。首先通过精密定轨获取参考历元的卫星初始状态进行动力学积分及外推得到观测弧段轨道和预报弧段轨道,将动力学积分结果与外部参考轨道进行比较作差,得到观测弧段轨道误差和预报弧段轨道误差。此外,动力学积分过程中输出的特征也将作为输入参与模型训练和预测。

2)预处理。获得实验数据集后,首先对数据集进行特征值筛选,去掉冗余特征,避免模型出现过拟合问题。然后将不同类型的特征数据及轨道预报误差数据进行归一化处理,统一到同一尺度下。

3)模型预测及修正。将预处理后的实验数据集划分为训练集和测试集,其中训练集用于模型训练,训练完成后,利用测试集进行模型性能

测试,模型输出预报弧段轨道误差,修正原始动力学预报轨道,从而得到机器学习结合动力学积分的预报轨道。

2 实验数据及模型配置

2.1 实验数据集

本文基于Sentinel-3A卫星数据开展实验。Sentinel-3A为欧洲航天局(European Space Agency, ESA)于2016年发射的低轨卫星^[18],其轨道高度为814.5 km,搭载了GPS接收机、激光反射器等载荷,其数据可从ESA的哥白尼数据中心获取(<https://scihub.copernicus.eu/maintenance.html#/home>)。本文选用数据集覆盖时段为2019-01-01—2019-07-14,采用武汉大学测绘学院自研的GREAT(GNSS+research, application, and teaching)软件^[19]进行精密定轨解算,历元间隔为30 s,弧段长度设为24 h,并外推预报24 h。采用ESA发布的科学轨道产品作为外部参考轨道。数据集每个历元均包含当前时刻的切向(along, A)、法向(cross, C)、径向(radial, R)三轴轨道预报误差,以及表1所列出的轨道相关特征。将数据集的前130个弧段数据作为训练数据,剩余部分用作测试。考虑到不同方向误差的差异,模型对A/C/R三轴轨道预报误差分别进行训练。

表1 动力学轨道特征

Table 1 Features of Dynamical Orbit

含义	特征
低轨卫星轨道六根数	E_A、E_E、E_I、E_OMEGA、E_W、E_M
低轨卫星总加速度	AA、AC、AR
N体引力加速度	AA_pm、AC_pm、AR_pm
地球重力加速度	AA_gr、AC_gr、AR_gr
相对论效应加速度	AA_re、AC_re、AR_re
大气阻力加速度	AA_at、AC_at、AR_at
太阳光压加速度	AA_sr、AC_sr、AR_sr
经验力加速度	AA_cu、AC_cu、AR_cu
轨道坐标系下太阳位置	PA_sun、PC_sun、PR_sun
大气密度	DENSITY
地磁指数	GEOMAG_AP
太阳辐射能量	SOLAR_FLUX
历元	EPO

2.2 模型参数配置

3种模型的主要参数配置如表2所示。其中SVM模型使用linear核函数,BP、LSTM神经网络

络分别使用 tanh、linear 激活函数,并使用 Adam 优化器。LSTM 神经网络加入了 Dropout 层以缓解过拟合问题^[20],并将 Dropout 层丢弃率设为 0.2。

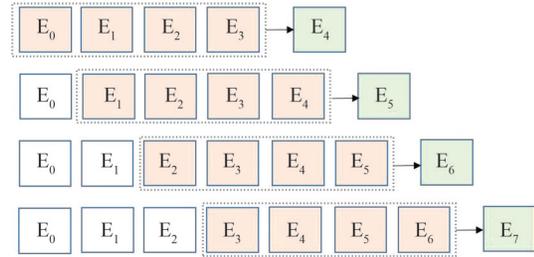
表 2 模型主要参数配置

Table 2 Primary Parameter Configuration of the Model

模型	激活函数/核函数	优化器	Dropout 系数
SVM	linear	—	—
BP	tanh	Adam	—
LSTM	linear	Adam	0.2

SVM 与 BP 模型基于单个历元的轨道误差相关特征预测该历元的轨道预报误差,因此无需用到观测弧段的数据。两种模型均以筛选出的特征值作为输入数据,特征筛选过程如 §3.1 所示。

LSTM 模型不使用特征数据,直接对历史轨道预报误差进行学习,并基于历史误差数据进行时序预测得到预报轨道的预测误差,因此需要使用观测弧段数据。具体时序预测方式如下:(1)设置滑动窗口,若令窗口大小为 4,则包含 4 个历元的误差数据;历元间隔为 30 s,窗口对应覆盖时长为 2 min。第一次预测时窗口内全为历史轨道预报误差数据,得到第一个预测历元的值。(2)丢弃窗口中第一个历元的数据,将上一次预测的值作为窗口中最后一个历元加入,得到第二个预测历元的值。(3)窗口进行滑动,重复上述操作,直至预测完成。图 2 展示了窗口滑动进行预测的过程。



注:窗口大小为 4,黑色为历史数据,红色为预测数据。

图 2 LSTM 的预测方式示意

Fig. 2 Prediction Method of LSTM

3 数据预处理

3.1 基于 XGBoost 的训练特征筛选

动力学积分产生的特征较多,因此需要进行特征值筛选去掉冗余特征,避免训练时出现过拟合问题。本文选取极端梯度提升(extreme gradient boosting, XGBoost)方法对特征进行重要性排序。XGBoost 是梯度提升决策树的一种系统实现,其树模型通过特征分裂产生,可以量化每个特征值的重要性,为特征选择提供依据^[21-22]。图 3 展示了根据特征重要性排序后的前 16 个特征。从图 3 可以看出,太阳位置(PC_sun)、历元(EPO)和大气阻力加速度(AA_at)这 3 个特征的重要性最高,这与轨道预报误差变化规律一致:随时间增加,轨道误差逐渐发散。大气阻力与太阳光压力是对低轨卫星定轨影响较大的摄动力。

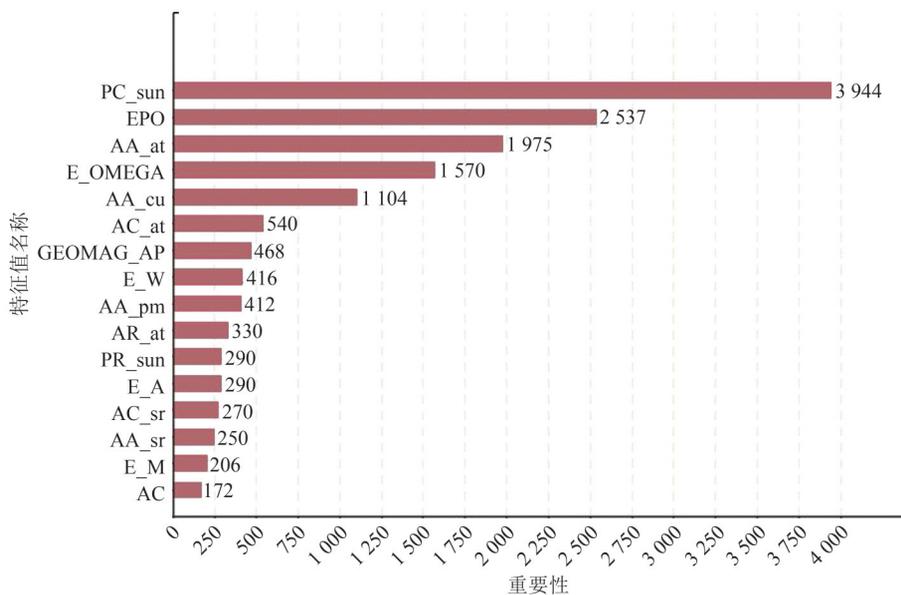


图 3 Sentinel-3A 卫星特征重要性排序结果(前 16 个)

Fig. 3 Sorting Result of Sentinel-3A Satellite's Features (Sixteen Features Most Important)

3.2 数据归一化

轨道预报误差、特征值有不同的量纲和较大的数值差别,直接输入模型会影响训练结果,降低训练速度。为加速训练收敛,实验中需将数据集进行归一化。使用数据中的最大值 x_{\max} 和最小值 x_{\min} 将所有原数据 x_{origin} 映射到 $[0,1]$ 区间内:

$$x_{\text{new}} = \frac{x_{\text{origin}} - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x_{new} 为归一化值。数据集中存在的粗差可能使得 x_{\max} 过大,导致归一化结果不稳定,进而影响最终的预测效果,因此在实验前需要对数据集进行粗差剔除。每个弧段内的最大预报误差能够在一定程度上反映该弧段的精度水平,取所有弧段的最大预报误差构成集合,使用标准差法对离群值进行检测。检测出的离群值判定为粗差,并对粗差所在的整个弧段数据进行剔除。

4 实验结果

4.1 最优模型参数选定

模型参数的配置需要参考模型预报的误差与真实误差的符合程度,其以残差率 P 衡量:

$$P = \sum_{i=1}^n |y_i - \hat{y}_i| / \sum_{i=1}^n |y_i| \quad (2)$$

式中, y 为原轨道误差数据; \hat{y} 为机器学习模型输出的预测误差。 P 理想取值范围为 $[0,1]$,取值越小,模型预报误差与实际误差拟合越好;越接近1,改善越不明显。 $P > 1$,表示模型可能带来负面效果。为评价机器学习对于轨道预报的精度改善情况,统计了A/C/R各方向的 P ,同时对3D P 进行了计算,以评估总体的精度提升。

本文轨道预报时间设置为180 min,即Sentinel-3A卫星的近实时产品数据采集至更新的时延^[23]。为评估各模型在不同预报时长下的性能,以20 min为间隔,设置了预报时长从20~180 min多组实验。

4.1.1 SVM、BP的特征数量选定

SVM与BP神经网络的输入特征数量会对模型性能产生直接的影响。作为一个例子,图4

和图5分别展示了SVM、BP在40 min预测中 P 随特征数量的变化情况。在图4中,特征数量为5时,SVM模型的3D P 达到最小。图5中,在特征数量为5时,A方向和3D P 同时达到最小。因此,分别选择5和4作为SVM和BP在40 min时的最佳特征数量。按照特征重要性的排序(图3)依次采用特征,即SVM模型采用PC_sun、EPO、AA_at、E_OMEGA、AA_cu,BP模型采用PC_sun、EPO、AA_at、E_OMEGA。可以发现,A方向与3D P 变化情况基本一致,这是因为A方向与卫星运动速度方向同向,受大气阻力影响大、精度衰减迅速,对整体精度起着主导作用。

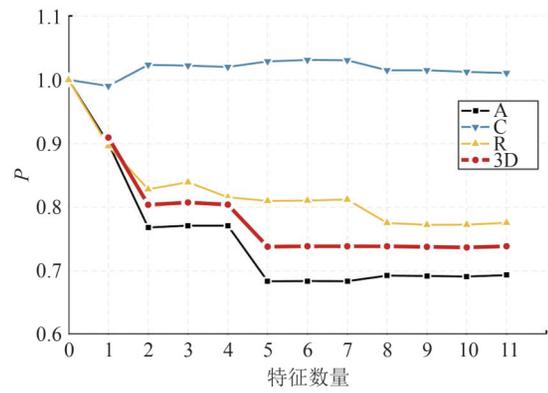


图4 SVM在40 min预测中的 P 结果

Fig. 4 P Results of SVM for 40 min's Prediction

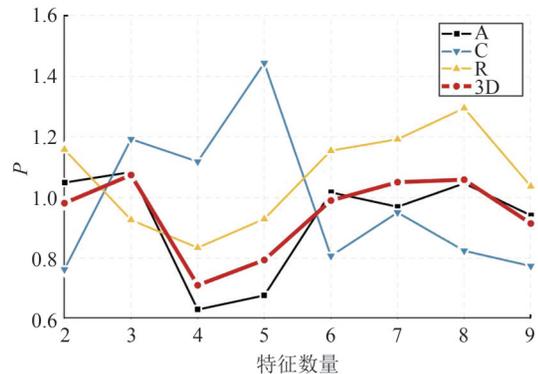


图5 BP神经网络在40 min预测中的 P 结果

Fig. 5 P Results of BP Neural Network for 40 min's Prediction

通过以上方式选取的SVM、BP模型在不同预测时长下的最佳配置参数如表3所示。

表3 SVM、BP模型最佳参数选定结果

Table 3 Optimal Parameters for SVM and BP Models

统计项	时长/min								
	20	40	60	80	100	120	140	160	180
SVM特征数量	5	5	5	5	5	5	4	3	3
BP特征数量	4	4	5	7	7	11	12	13	14

4.1.2 LSTM的窗口大小选定

LSTM神经网络的滑动窗口大小是模型的重要参数,会影响模型性能。同样以40 min的预测为例,图6展示了LSTM在预测时中P随滑动窗口大小的变化情况。

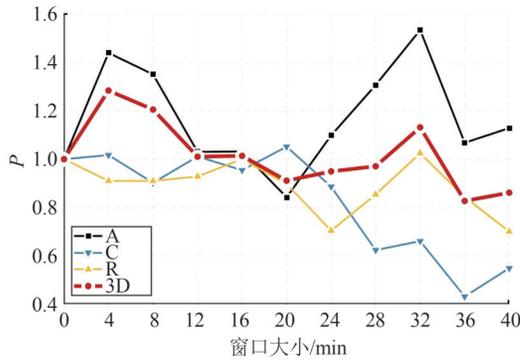


图6 LSTM神经网络在40 min预测中的P结果
Fig. 6 P Results of LSTM Neural Network for 40 min's Prediction

图6中,窗口大小对应着窗口内数据覆盖的时间长度,窗口越大,模型训练所需的时间越长,为保证模型训练的效率,本文限定窗口大小不超过预测时间长度。图6中3D P在窗口大小为36 min时最小,因此选择36 min作为预报时长40 min时的最佳窗口大小。最终选定的LSTM模型在不同预测时长下的最佳配置参数如表4所示。

4.2 3种模型改善效果

为比较3种机器学习模型轨道预报的性能,将模型修正后的预报轨道与外部参考轨道进行比较,计算预报轨道的精度提升百分比。表5统计了不同预报时长下的3D P值和总体的轨道精度提升百分比,可以看到,P值与精度提升百分比对轨道改善情况的反映基本一致。SVM与BP模型对轨道精度的改善效果基本随预报时间的增长而提升,LSTM模型对轨道精度的改善则明显随预报时间的增长而下降。

表4 LSTM模型最佳参数选定结果

Table 4 Optimal Parameters for LSTM Model

窗口大小	时长/min								
	20	40	60	80	100	120	140	160	180
LSTM窗口大小	20	36	30	40	50	72	70	80	90

表5 3种模型在不同预测时长下对预报轨道的改善效果
Table 5 Improvement of Three Models on Predict Orbits for Different Predict Time

预测时长/min	SVM		BP		LSTM	
	3D P	精度提升/%	3D P	精度提升/%	3D P	精度提升/%
20	1.03	-0.1	1.01	-1.2	0.59	38.1
40	0.74	28.2	0.70	33.2	0.87	10.6
60	0.65	37.2	0.71	30.5	0.97	1.7
80	0.53	50.1	0.56	47.1	0.92	6.1
100	0.48	52.1	0.54	47.7	1.02	-8.9
120	0.62	40.9	0.78	24.7	1.00	2.9
140	0.62	40.0	0.61	43.3	1.03	-5.9
160	0.59	42.8	0.76	23.4	1.40	-39.5
180	0.52	49.8	0.51	48.5	2.14	-102.2

为进一步分析机器学习轨道预报的精度,图7对比了20 min、100 min及180 min轨道预报实验中3种模型修正前后的预报轨道与外部参考轨道比较差异的RMS,当预报时长为20 min时(图7(a)),原始动力学预报轨道精度为1.72 cm,而3种模型修正后精度分别为1.73 cm(SVM)、1.75 cm(BP)及1.07 cm(LSTM)。此时LSTM模型的性能优于SVM、BP模型的性能。当预测时长为

100 min时(图7(b)),原始动力学预报轨道精度为8.17 cm,而LSTM模型修正后的轨道精度为8.89 cm,较多弧段超过10 cm。SVM、BP模型的预报轨道精度分别为3.91 cm、4.31 cm,各弧段的精度基本保持在6 cm以内,明显优于LSTM模型。预报时长为180 min时(图7(c)),原始动力学预报轨道精度为13.28 cm,SVM与BP模型结果基本一致,预报轨道精度分别为6.67 cm及6.86 cm,精度提升百分比分别为49.8%和48.5%,此时LSTM预报轨道精度为26.8 cm。这说明当预报时长为180 min时,SVM和BP模型可以显著改善轨道预报精度,改善幅度可达50%左右,且改善后的轨道预报精度可以达到7 cm以内。

对比表5、图7中不同预报时长的结果可以发现,LSTM模型更适合于20 min左右的轨道预报,且模型性能随预报时长增加而逐渐变差,这是因为随着预测时间的增加,窗口持续滑动,距离真实历史误差区域越远,窗口内数据完全被预测数据替代,预测偏差在该过程中逐渐累积,使得更长时间的预测偏差更大。SVM和BP模型更适合于40 min以上的轨道预报,并且SVM模

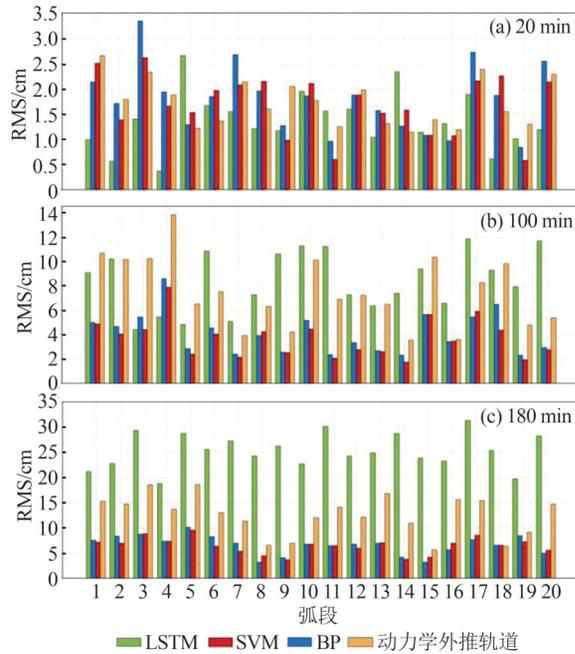


图 7 预测弧段 RMS

Fig. 7 RMS of Predict Arcs

型的改善效果更为稳定, BP 模型则出现了较大的波动。

5 结 语

本文采取机器学习与传统动力学积分外推相结合的方式, 以提升低轨卫星短期轨道预报的精度。基于 Sentinel-3A 卫星 2019-01-01—2019-07-14 实测数据进行轨道预报实验, 实验数据包括预报轨道各方向误差以及多个与轨道误差相关的特征。选取了 SVM、BP、LSTM 神经网络 3 种模型, 首先对模型最优配置进行了探究, 然后基于各模型最优配置进行实验, 从多个角度评估了各模型对于轨道预报精度的提升效果, 并对不同模型在低轨卫星轨道预报中的适用性进行了深入分析, 得出的主要结论如下:

1) 在预测时长为 20 min 时, LSTM 模型的性能要显著优于 SVM 和 BP 模型的性能, 相应的 P 为 0.59, 对预报轨道的精度提升为 38.1%, 提升后的平均轨道精度为 1.07 cm (3D)。相比之下, SVM 和 BP 模型对于预报轨道精度的提升效果不显著, 因此在预报时长为 20 min 左右时更适合选用 LSTM 模型。

2) 当预报时间大于 40 min 时, SVM 与 BP 模型性能则明显优于 LSTM 模型。SVM 模型在 60 min 以上的各预报时长下, 轨道精度提升均在 40% 以上, 预报时长为 180 min 时, 精度提升达到 49.8%, 改善后的平均轨道精度为 6.67 cm。BP 模

型在 180 min 时取得最优效果, 精度提升达到 48.5%, 改善后的轨道精度为 6.86 cm。而 LSTM 模型性能则随预报时间的增加而逐渐下降, 在 100 min 以后对轨道精度已无明显提升效果。因此, SVM 和 BP 模型更适合于 40 min 以上的轨道预报。

本文实验结果表明, 将机器学习与传统动力学积分轨道预报方法相结合, 能够显著提升低轨卫星短期预报轨道的精度, 从而有望进一步提升低轨导航增强星座的服务性能。尽管文中使用的特征集包含了 34 个特征, 但仍可能存在与轨道预报误差有较强相关性的特征未被利用, 如果加入更多的与轨道预报误差强相关的特征, 机器学习方法对轨道预报精度的改善效果有望进一步得到提升。此外, 本文使用轨道高度为 814.5 km 的 Sentinel-3A 卫星进行实验, 对于轨道高度相差较大及不同轨道类型的卫星, 受到大气阻力以及太阳光压等非保守摄动力影响的差异较大, 因此在相同时间内的轨道预报误差发散程度不一致, 同时与轨道预报误差相关的特征重要性排序也会有所差异。因此在处理不同的卫星时需要重新进行特征排序, 并对模型策略做出相应调整。

参 考 文 献

- [1] REID T G, NEISH A M, WALTER T F, et al. Leveraging Commercial Broadband LEO Constellations for Navigating [C]//The 29th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+ 2016), Portland, Oregon, USA, 2016.
- [2] GE H B, LI B F, GE M R, et al. Initial Assessment of Precise Point Positioning with LEO Enhanced Global Navigation Satellite Systems (LeGNSS)[J]. *Remote Sensing*, 2018, 10(7): 984.
- [3] LI X X, MA F J, LI X, et al. LEO Constellation-Augmented Multi-GNSS for Rapid PPP Convergence [J]. *Journal of Geodesy*, 2019, 93(5): 749-764.
- [4] 曾添, 隋立芬, 贾小林, 等. 小型化 LEO 星座与 BDS-3 全星座联合定轨仿真[J]. *武汉大学学报(信息科学版)*, 2022, 47(1): 61-68.
ZENG Tian, SUI Lifen, JIA Xiaolin, et al. Simulation of Combined Orbit Determination with a Small LEO Constellation and BDS-3 Full Constellation [J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(1): 61-68.
- [5] TENG Y H, JIA X L, PENG G. LEO Navigation Augmentation Constellation Design and Precise

- Point Positioning Performance Analysis Based on BDS-3[J]. *Advances in Space Research*, 2023, 72(6): 1944-1960.
- [6] 常志巧, 郝金明, 张成军. GPS精密星历的外推精度分析[J]. *测绘工程*, 2006, 15(2): 27-29.
CHANG Zhiqiao, HAO Jinming, ZHANG Chengjun. Precision Analysis of Orbit Prediction of GPS Satellites[J]. *Engineering of Surveying and Mapping*, 2006, 15(2): 27-29.
- [7] GE H B, LI B F, GE M R, et al. Improving Low Earth Orbit (LEO) Prediction with Accelerometer Data[J]. *Remote Sensing*, 2020, 12(10): 1599.
- [8] PENG H, BAI X L. Using Artificial Neural Network in Machine Learning Approach to Improve Orbit Prediction Accuracy [C]// Space Flight Mechanics Meeting, Kissimmee, Florida, 2018.
- [9] PENG H, BAI X L. Improving Orbit Prediction Accuracy Through Supervised Machine Learning [J]. *Advances in Space Research*, 2018, 61(10): 2628-2646.
- [10] 曹磊. 基于深度神经网络补偿模型的轨道预报技术[D]. 南京: 南京航空航天大学, 2014.
CAO Lei. Satellite Orbit Prediction Method based on Compensation Model by Using Deep Neural Network [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2014.
- [11] 杨先睿. 基于深度学习的卫星轨道预报算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.
YANG Xianrui. Research on Satellite Orbits Predicting Algorithm Based on Deep Learning[D]. Harbin: Harbin Institute of Technology, 2019.
- [12] 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.
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.
- [13] 孙轶轩, 邵春福, 计寻, 等. 基于ARIMA与信息粒化SVR组合模型的交通事故时序预测[J]. *清华大学学报(自然科学版)*, 2014, 54(3): 348-353.
SUN Yixuan, SHAO Chunfu, JI Xun, et al. Urban Traffic Accident Time Series Prediction Model Based on Combination of ARIMA and Information Granulation SVR[J]. *Journal of Tsinghua University (Science and Technology)*, 2014, 54(3): 348-353.
- [14] RUMELHART D E, MCCLELLAND J L, GROUP P R. Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations[M]. Cambridge: The MIT Press, 1986.
- [15] 陈志高, 吴子豪, 班亚, 等. 基于调和分析及VMD-BP神经网络的感潮河段流量预报[J]. *武汉大学学报(信息科学版)*, 2023, 48(8): 1389-1397.
CHEN Zhigao, WU Zihao, BAN Ya, et al. Discharge Prediction in Tidal Reach Using Harmonic Analysis and VMD-BP Neural Network [J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(8): 1389-1397.
- [16] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [17] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. *计算机应用*, 2018, 38(S2): 1-6.
YANG Li, WU Yuxi, WANG Junli, et al. Research on Recurrent Neural Network [J]. *Journal of Computer Applications*, 2018, 38(S2): 1-6.
- [18] The European Space Agency. Rise and Shine for Sentinel-3A [EB/OL] (2016-01-14). https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-3/Rise_and_shine_for_Sentinel-3A.
- [19] LI X X, HAN X J, LI X, et al. GREAT-UPD: An Open-Source Software for Uncalibrated Phase Delay Estimation Based on Multi-GNSS and Multi-Frequency Observations [J]. *GPS Solutions*, 2021, 25(2): 66.
- [20] 杨青, 王晨蔚. 基于深度学习LSTM神经网络的全球股票指数预测研究[J]. *统计研究*, 2019, 36(3): 65-77.
YANG Qing, WANG Chenwei. A Study on Forecast of Global Stock Indices Based on Deep LSTM Neural Network [J]. *Statistical Research*, 2019, 36(3): 65-77.
- [21] 李占山, 刘兆康. 基于XGBoost的特征选择算法[J]. *通信学报*, 2019, 40(10): 101-108.
LI Zhanshan, LIU Zhaogeng. Feature Selection Algorithm Based on XGBoost [J]. *Journal on Communications*, 2019, 40(10): 101-108.
- [22] 王德运, 张露丹, 吴祈, 等. 基于机器学习算法的洪涝灾害风险评估: 以宜昌市为例[J]. *长江流域资源与环境*, 2023, 32(8): 1710-1723.
WANG Deyun, ZHANG Ludan, WU Qi, et al. Flood Risk Assessment Based on Machine Learning Algorithms: A Case Study of Yichang City [J]. *Resources and Environment in the Yangtze Basin*, 2023, 32(8): 1710-1723.
- [23] The European Space Agency. Near Real-Time, Slow-Time Critical or Non-Time Critical [EB/OL]. (2023-10-17) <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-3-altimetry/product-types/nrt-or-ntc>.