引文格式：郑建雷,陈淼新. 利用 Prophet-PSO-LSTM 模型预测地表沉降[J]. 地理空间信息, 2026, 24(7): 81-85. doi:10. 3969/j.issn. 1672-4623.2026.07.015

利用 Prophet-PSO-LSTM 模型预测地表沉降

郑建雷，陈淼新
（中水珠江规划勘测设计有限公司，广东 广州 510610）

摘　要：针对复杂地质条件或工程活动影响下的地表沉降，单一模型预测往往难以充分挖掘沉降数据时序信息，导致预测精度受限。将粒子群优化算法（PSO）用于长短记忆神经网络（LSTM）模型的超参数优化，并结合 Prophet 时间序列模型提出了 Prophet-PSO-LSTM 模型。利用某地表沉降监测数据对该组合模型进行了验证。结果表明，Prophet-PSO-LSTM 模型的 MAE、RMSE 和 MAPE 均优于 Prophet 模型、PSO-LSTM 模型和 Prophet-LSTM 模型，说明其在充分挖掘沉降数据时序信息方面具有较大的优势。

关键词：地表沉降；Prophet 模型；PSO 算法；LSTM 模型；组合模型
中图分类号：P258　　**文献标志码：**B　　**文章编号：**1672-4623（2026）07-0081-05

Surface Settlement Prediction Using Prophet-PSO-LSTM Model

ZHENG Jianlei, CHEN Miaoxin
(China Water Resources Pearl River Planning Surveying & Designing Co., Ltd., Guangzhou 510610, China)

Abstract: Aiming at surface settlement under the influence of complex geological conditions or engineering activities, single model prediction is often difficult to fully exploit the time-series information of settlement data, resulting in limited prediction accuracy. For this reason, we applied the particle swarm optimization (PSO) algorithm to optimize the hyperparameters of long- and short-term memory neural network (LSTM) model, and combined with Prophet time-series model to establish Prophet-PSO-LSTM model. Then, we validated the combined model by a surface settlement monitoring data. The results show that the Prophet-PSO-LSTM model is superior to the Prophet model, PSO-LSTM model and Prophet-LSTM model in MAE, RMSE and MAPE indexes, which indicating that the combined model has greater advantages in fully exploiting the time-series information of settlement data.

Key words: surface settlement, Prophet model, PSO algorithm, LSTM model, combined model

地表沉降是指一个地区受人类生产生活影响和地下松散固结压缩而导致的地球表面高程降低[1-2]。地表沉降不仅会破坏原有的地表结构，还会造成地表建筑物的破坏、地下水污染和耕地破坏，甚至还会导致岩层倒塌、断裂等，威胁居民的人身安全[3-4]。因此，如何有效监测和预测地表沉降，对于基础设施的安全性、城市规划和公共安全等具有重要意义。地表沉降预测方法包括基于物理机制的方法、基于数理统计的方法和基于机器学习的方法等[5-11]。基于物理机制的方法可融合岩性特征、水文特征等内在物理参数，揭示地表沉降的物理本质，可解释性强；但计算复杂度高，参数依赖性强，建模难度大且短期预测不足。基于数理统计的方法简单易用、计算效率高，对机理不明的地表沉降现象具有一定的适应性；但预测结果依赖历史数据的统计规律，外推能力差且多因素耦合难。基于机器学习的方法非线性建模能力强，能很好地实现多源数据融合且实时更新能力强，但需要大量高质量数据，且易出现过拟合风险。Prophet 模型以其卓越的时间分解能力和灵活性，在捕捉趋势性和周期性变化方面备受关注。粒子群优化（PSO）算法能有效解决许多复杂的优化问题，优良的收敛性能使其在神经网络参数优化方面展现出巨大的潜力。长短期记忆网络（LSTM）是一种专门针对时间序列的递归神经网络，特别适用于需要考虑历史时间序列信息的预测任务。基于上述理论，本文提出了一种结合 Prophet、PSO 与 LSTM 的地表沉降组合预测模型。该模型充分考虑了时间序列数据的非线性和复杂性，不仅弥补了 Prophet 模型对非线性部分预测效果差的问题，而且考虑了 LSTM 模型超参数设定取决于人为经验的问

第一作者简介：郑建雷（1989—），硕士，高级工程师，从事水利水电工程安全监测工作，E-mail：821578912@qq.com。

题，能充分挖掘沉降时序数据中的有效信息，提升模型的拟合效果和预测能力。

1 理论模型与评价指标

1.1 Prophet模型

Prophet模型[12]是Facebook团队2017年开发的一种新的时间序列模型[13]，特别适用于具有趋势、季节性且包含缺失值和异常值等特点的时间序列数据。根据时间序列数据特点，可按照加性或乘性模式的数学原理获得最终预测值，其本质是对时间序列曲线的拟合[14]。Prophet模型时间序列的表达式为：

$$y(t)=g(t)+s(t)+h(t)+\varepsilon_t \tag{1}$$

式中：$g(t)$为趋势项，反映时序数据的变化趋势；$s(t)$为周期项，通常以周或年为单位；$h(t)$为假日项，即时间序列中节假日对预测变量的影响；ε_t为残差项。

Prophet模型是一个自带分解功能的强大且灵活的时间序列模型，可将分解的趋势项建模为线性或饱和增长，利用傅里叶级数构建周期项，利用指数函数捕捉假期效应，并自动处理时序数据中的异常值。Prophet模型的核心在于运用贝叶斯框架估计趋势斜率、傅里叶系数和假期效应等参数，从而生成预测值、提供置信区间，以评估预测结果的不确定性。沉降监测时序数据的采集获取不受节假日影响，因此本文将Prophet模型中的节假日项去除。

1.2 PSO-LSTM模型

1.2.1 LSTM模型

LSTM模型是Hochreiter等[15]为解决传统循环神经网络模型梯度消失和梯度爆炸问题而提出的[16]；包括遗忘门、输入门、输出门和细胞状态4个核心组成部分，通过门控机制来控制信息的流动，从而解决循环神经网络在处理长序列时的梯度消失和梯度爆炸问题[17]。

首先，计算遗忘门f_t，输入当前时间步t的输入向量$\boldsymbol{x}_t$、上一个时间步的隐藏状态h_{t-1}和细胞状态C_{t-1}，则有：

$$f_t=\sigma\left(\boldsymbol{W}_f x_t+\boldsymbol{U}_f h_{t-1}+b_f\right) \tag{2}$$

式中，σ为Sigmoid激活函数；$\boldsymbol{W}$和$\boldsymbol{U}$分别为x_t和h_{t-1}的权重矩阵；b_f为偏置项；f_t可控制上一时刻状态对当前状态的影响。

然后，计算输入门i_t和候选记忆$\tilde{C}_t$，输入门为控制当前输入信息的重要性。

$$i_t=\sigma\left(\boldsymbol{W}_i x_t+\boldsymbol{U}_i h_{t-1}+b_i\right) \tag{3}$$

$$\tilde{C}_t=\tanh\left(\boldsymbol{W}_c x_t+\boldsymbol{U}_c h_{t-1}+b_c\right) \tag{4}$$

式中，tanh为双曲正切函数，范围为[−1,1]。

最后，计算输出门o_t，并更新当前时间步的细胞状态和隐藏状态。

$$o_t=\sigma\left(\boldsymbol{W}_o x_t+\boldsymbol{U}_o h_{t-1}+b_o\right) \tag{5}$$

$$C_t=f_t C_{t-1}+i_t\tilde{C}_t \tag{6}$$

$$h_t=o_t\tanh\left(C_t\right) \tag{7}$$

1.2.2 PSO算法

PSO算法[18]是一种全局寻优算法，其原理是粒子从随机解出发迭代更新粒子的速度和位置直至寻找最优解。PSO粒子群的速度位置更新公式为：

$$v_{id}^{\kappa+1}=\omega v_{id}^{\kappa}+c_1\mathrm{rand}\left(p_{id}-\mu_{id}^{\kappa}\right)+$$

$$c_2\mathrm{rand}\left(p_{gd}-\mu_{id}^{\kappa}\right)\mu_{id}^{\kappa+1}=\mu_{id}^{\kappa}+v_{id}^{\kappa+1} \tag{8}$$

式中，κ为迭代次数；ω为惯性权重；$d=1,2,\cdots,N$；$i=1,2,\cdots,M$，M为种群规模；c_1、c_2为学习因子；rand为0~1的随机整数；v_{id}^{κ}、μ_{id}^{κ}为粒子的速度和位置；p_{id}为粒子当前最优位置；p_{gd}为全局范围内的最优位置。

1.2.3 PSO-LSTM模型

LSTM模型参数分为普通参数和超参数，其中普通参数包括权值和偏置值，由TensorFlow内置优化算法计算梯度，并更新参数获得最优解[19-22]；超参数通常在模型训练前由人工指定，对模型的预测性能具有显著影响。本文的参数优化步骤包括：①对沉降数据进行预处理和归一化，形成LSTM训练集和测试集；②输入训练集，利用LSTM模型对模型参数进行训练，确定待优化超参数取值范围；③设置PSO算法参数，利用PSO算法对LSTM超参数进行寻优；④对比粒子的适应度，计算最优适应度值，满足最大迭代次数后输出最优的粒子信息，即为模型的最优超参数；⑤构建LSTM模型并训练，输出沉降预测值。

1.3 精度评定

本文选取平均绝对误差（MAE）、均方根误差（RMSE）和平均绝对百分比误差（MAPE）作为评价指标，对预测结果进行对比分析。

$$\mathrm{MAE}=\frac{\sum_i\left|y_i-\hat{y}_i\right|}{n} \tag{9}$$

$$\mathrm{RMSE}=\sqrt{\frac{\sum_i\left(y_i-\hat{y}_i\right)^2}{n}} \tag{10}$$

$$\mathrm{MAPE}=\frac{1}{n}\sum_i\left|\frac{\left(y_i-\hat{y}_i\right)}{y_i}\right|\times 100\% \tag{11}$$

式中，n 为测试数据数量；y_i、$\hat{y}_i$ 为数据实际值和预测值。

2　组合模型建模

基于上述理论，本文提出了 Prophet–PSO–LSTM 沉降预测模型。Prophet–PSO–LSTM 模型结合历史沉降时序数据进行训练，并预测未来沉降变化情况。构建 Prophet–PSO–LSTM 模型的步骤包括：①收集和整理历史沉降时序数据，确保数据以时间序列的格式呈现，并将整理好的原始时序数据进行预处理；②将预处理后的数据划分为训练集和测试集，训练集用于构建组合预测模型，测试集用于验证模型预测效果，利用 Prophet 模型自带的分解功能将预处理后的数据分解为趋势项、周期项和残差项，根据数据特征设置 Prophet 模型参数，并对趋势项和周期项进行拟合预测，输出预测值 $P(t)$；③根据数据特征设置 LSTM 模型参数，利用 PSO 算法优化 LSTM 模型超参数，利用 PSO–LSTM 模型分别对 Prophet 模型分解的残差项和原始沉降数据进行预测，输出预测值 $L_1(t)$ 和 $L(t)$；④对 Prophet 模型分解的 3 个预测值进行等权相加得到预测值 $[P(t)+L_1(t)]$；⑤基于方差倒数法确定 $[P(t)+L_1(t)]$ 和 $L(t)$ 的权重系数 w_p 和 w_l，进而构建 Prophet–PSO–LSTM 组合模型，得到最终预测值 $Y(t)=w_p[P(t)+L_1(t)]+w_lL(t)$。

3　模型应用与分析

本文选取云南省某地区隧洞地表沉降监测数据进行机器学习实验。该隧洞采用光面爆破开挖掘进，地质条件复杂，存在浅埋洞段，岩性为断裂破碎带，埋深仅为 6~15 m。以埋深最浅的地表沉降监测点 2020—2023 年沉降观测数据为模型验证的样本数据，将观测数据预处理后的沉降时序样本数据按照 3∶1 的比例划分训练集和测试集。

3.1　Prophet 模型预测

为减少数据的非线性与非平稳特征，利用 Prophet 模型将训练集数据分解为 3 个主要部分：由逻辑回归函数拟合的趋势项、基于傅里叶级数构建的以年为周期的周期项以及其他部分作为随机波动残差项。根据沉降时序的数据特征设置 Prophet 模型的参数，利用 Prophet 模型对 2020—2022 年的数据进行拟合，并对 2023 年沉降数据进行预测。拟合和预测结果见图 1、2，预测精度见表 1，可以看出，Prophet 模型对于数据拟合预测效果较好，测试集拟合预测效果略优于训练集。

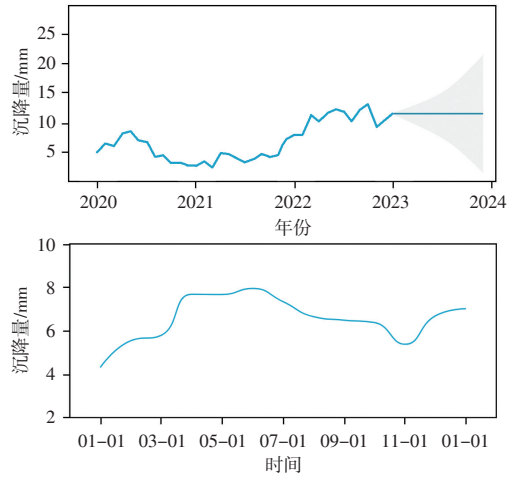


图 1　Prophet 模型的趋势和周期预测

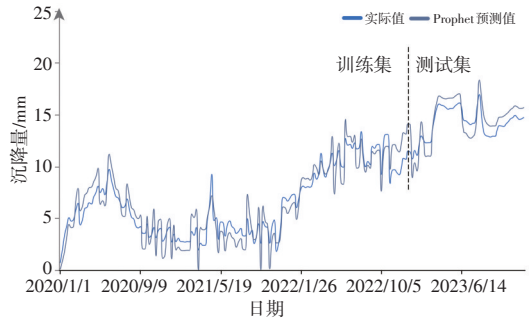


图 2　Prophet 模型预测结果曲线图

表 1　Prophet 模型预测精度

训练集			测试集		
MAE/mm	RMSE/mm	MAPE/%	MAE/mm	RMSE/mm	MAPE/%
1.12	1.27	22.84	1.03	1.11	7.47

3.2　PSO–LSTM 模型预测

LSTM 模型的超参数设定通常依赖于人为经验，往往会导致模型预测效果一般。本文利用 PSO 算法优化 LSTM 模型的超参数，再使用优化后的最佳参数构建并训练 LSTM 模型，然后利用训练好的模型进行沉降预测并输出结果。LSTM 模型的超参数寻优结果见表 2，优化后的 LSTM 模型预测结果见图 3，预测精度见表 3，可以看出，PSO–LSTM 模型预测

的沉降变化规律与实际沉降规律大体一致，对该序列的拟合和预测效果较好，但对突变点的拟合效果略差。

表2 LSTM模型超参数寻优结果

超参数	寻优范围	寻优结果
学习率	0.001~0.050	0.007
第一层隐藏层神经元数量/个	32~500	202
第二层隐藏层神经元数量/个	32~500	94
最大迭代次数/次	50~500	163

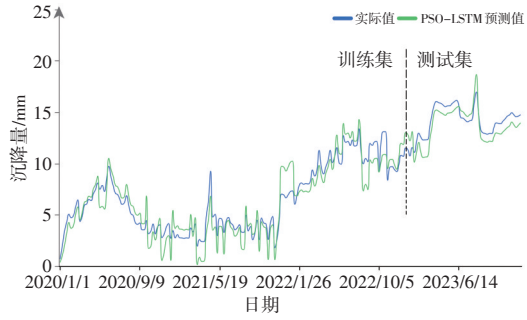


图3 PSO-LSTM模型预测结果曲线图

表3 PSO-LSTM模型预测精度

训练集			测试集		
MAE/mm	RMSE/mm	MAPE/%	MAE/mm	RMSE/mm	MAPE/%
1.05	1.25	21.16	0.94	1.01	6.87

3.3 Prophet-LSTM模型预测

为得到最佳预测结果，根据经验设定LSTM参数：学习率为0.001，模型隐含层为100，正则化参数为0.000 1，迭代次数为200。利用LSTM模型对残差项进行预测，并结合Prophet模型对趋势项和周期项的预测值以及LSTM模型对原始沉降时序数据的预测值，利用方差倒数法确定权重系数，进而获得组合模型的最终沉降预测值。通过分析原始沉降时序数据的拟合值残差，利用方差倒数法计算得到 w_p 和 w_l 的最优权重分别为0.3和0.7，则该组合模型的表达式为 $Y(t)=0.3[P(t)+L_1(t)]+0.7L(t)$ 。组合模型预测结果曲线见图4，预测精度见表4。

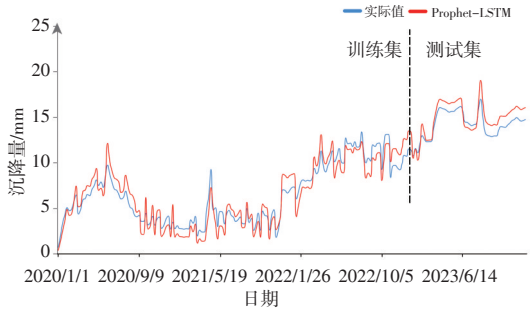


图4 Prophet-LSTM模型预测结果曲线图

表4 Prophet-LSTM模型预测精度

训练集			测试集		
MAE/mm	RMSE/mm	MAPE/%	MAE/mm	RMSE/mm	MAPE/%
1.04	1.15	19.40	0.93	1.03	6.56

3.4 Prophet-PSO-LSTM模型预测

由于Prophet模型对非线性部分的预测效果较差[23]，且其分解的残差项并非正态分布数据，因此本文利用PSO-LSTM模型对残差项进行预测，并结合Prophet模型对趋势项和周期项的预测值以及PSO-LSTM模型对原始沉降时序数据的预测值，利用方差倒数法确定权重系数，进而获得组合模型的最终沉降预测值。通过分析原始沉降时序数据的拟合值残差，利用方差倒数法计算得到 w_p 和 w_l 的最优权重分别为0.2和0.8，则该组合模型的表达式为 $Y(t)=0.2[P(t)+L_1(t)]+0.8L(t)$ 。组合模型的预测结果曲线见图5，预测精度见表5。

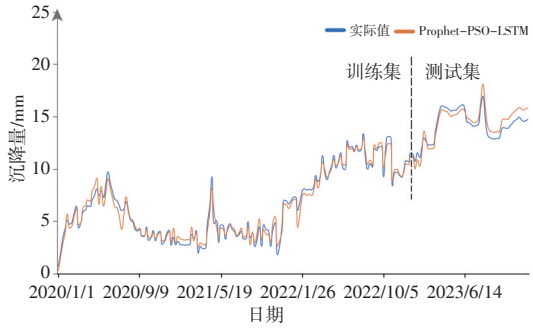


图5 Prophet-PSO-LSTM模型预测结果曲线图

表5 Prophet-PSO-LSTM模型预测精度

训练集			测试集		
MAE/mm	RMSE/mm	MAPE/%	MAE/mm	RMSE/mm	MAPE/%
0.93	1.22	18.81	0.80	1.01	5.71

3.5 结果分析

对比表1、3、4、5可知，Prophet-PSO-LSTM模型的各项评价指标均为最优，预测精度明显优于其他模型。相较于Prophet模型、PSO-LSTM模型和Prophet-LSTM模型，Prophet-PSO-LSTM模型训练集数据的MAE分别降低了16.8%、11.9%和11.2%，RMSE分别降低了3.9%、2.4%和提升了6.3%，MAPE分别降低了17.6%、11.1%和3.0%；测试集数据的MAE分别降低了22.3%、15.5%和14.1%，RMSE分别降低了9.2%、0.2%和2.0%，MAPE分别降低了23.6%、16.9%和12.9%，说明Prophet-PSO-LSTM模

型的预测精度明显提升，具有更强的预测性能。对比图2~5可知，Prophet–PSO–LSTM模型的预测曲线与实际曲线变化趋势吻合性更好；PSO–LSTM模型预测曲线略优于Prophet模型，其原因在于PSO–LSTM模型具有良好的非线性学习能力，说明Prophet–PSO–LSTM模型能很好地弥补单一模型的不足，且能充分利用沉降数据的时序信息。

4 结 论

本文将Prophet模型与PSO–LSTM模型相结合，提出了Prophet–PSO–LSTM组合模型，并与Prophet模型和PSO–LSTM模型进行了对比分析。结果表明：Prophet–PSO–LSTM模型的MAE、RMSE和MAPE均优于Prophet模型和PSO–LSTM模型，表现出更高的预测精度和更强的泛化能力；Prophet–PSO–LSTM模型能很好地弥补Prophet模型和PSO–LSTM模型的不足，充分挖掘沉降时序数据中的有效信息，从而提高组合模型的整体预测精度。

本文仅考虑了历史数据对地表沉降预测的影响，后续可考虑地质构造参数、地下水参数等多个影响因素。Prophet–PSO–LSTM模型结合了时间序列分解、PSO和LSTM的优点，可对多源数据进行融合，结合实时监测数据，动态更新模型参数，实现地表沉降异常的早期预警，减少灾害损失。

参考文献

[1] 李益敏,计培琨,杨雪,等. 基于PS-InSAR技术的地表形变监测与驱动力分析[J]. 地理空间信息,2024,22(9):61-66

[2] 王文辉,何毅,张立峰,等. 基于PS-InSAR和GeoDetector的兰州主城区地表变形监测与驱动力分析[J]. 兰州大学学报(自然科学版),2021,57(3):382-388

[3] Yang X L, Wen G C, Dai L C, et al. Ground Subsidence and Surface Cracks Evolution from Shallow-buried Close-distance Multi-seam Mining: A Case Study in Bulianta Coal Mine[J]. Rock Mechanics and Rock Engineering, 2019,52(8):2835-2852

[4] 王本浩,王延霞,项学泳,等. 结合DS-InSAR和LSTM的矿区地面沉降监测与预测[J]. 测绘通报,2024(11):44-48

[5] 刘青豪,张永红,邓敏,等. 大范围地表沉降时序深度学习预测法[J]. 测绘学报,2021,50(3):396-404

[6] 陈亦轩,李筱艳,陈松. 基于Peck公式的隧道盾构施工引起的地表沉降预测研究[J]. 安全与环境工程,2023,30(2):79-83

[7] 王琰,吕航,谷复光. 多元线性回归方法在地面沉降量预测中的解析及应用[J]. 安全与环境工程,2021,28(3):156-161

[8] 陈媛媛,赵秉琨,王慧,等. 基于LSTM模型的时序InSAR地表形变预测[J]. 人民长江,2024,55(3):146-152

[9] 俞晓军,葛文,吴春节. 基于IGOWLA算子的组合预测方法及应用研究[J]. 地理空间信息,2022,20(12):143-147

[10] 骆忠,蒙六清,金鑫,等. 综合多因素的矿山地表沉降安全性预测[J]. 采矿技术,2024,24(6):223-228

[11] 张子龙,潘秋景,仉文岗,等. 基于物理信息神经网络的盾构隧道诱发地表沉降预测[J]. 工程力学,2024,41(4):161-173

[12] Taylor S J, Letham B. Forecasting at Scale[J]. The American Statistician,2018,72(1):37-45

[13] 杜红兵,邢梦珂,赵德超. Prophet-LSTM组合模型在运输航空征候预测中的应用[J]. 安全与环境学报,2024,24(5):1878-1885

[14] 黄心裕,唐军,王晓宇. 基于Prophet算法的海南近海波浪长时段时序分析与预测[J]. 海洋学报,2022,44(4):114-121

[15] Hochreiter S, Schmidhuber J. Long Short-term Memory[J]. Neural Computation,1997,9(8):1735-1780

[16] 刘天翼,艾星星,张九丹. 基于MLR-DE-LSTM的大坝变形串联组合预测模型[J]. 中国农村水利水电,2025(2):207-212

[17] 张凯选,袁浩. 基于多源数据的GNSS高程预测[J]. 大地测与地球动力学,2024,44(12):1293-1298

[18] 郝泽嘉,施玉群,成博超,等. 基于PSO-LSTM的大坝变形组合预测模型[J]. 长江科学院院报,2025,42(5):208-214

[19] 徐嘉远,邹磊,夏军,等. TVGM-LSTM耦合模型及其径流模拟效果分析[J]. 水资源保护,2023,39(6):104-110

[20] 田烨,谭伟丽,王国庆,等. LSTM变体模型在径流预测中的性能及其可解释性[J]. 水资源保护,2023,39(3):188-194

[21] 石卓,史东华,姚成,等. 基于径流模数的LSTM模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版),2024,52(3):51-57

[22] 郭明辰,张润润,闻余华. 基于PSO-LSTM模型的平原河网汛期水位预测[J]. 水利水电科技展,2024,44(6):64-70

[23] 李威,鲁铁定,贺小星,等. 基于Prophet-RF模型的GNSS高程坐标时间序列预测分析[J]. 大地测量与地球动力学,2024,41(2):116-121