

# 顾及噪声影响的 GNSS 高程序列预测 Prophet 方法\*

鲁铁定<sup>1</sup>,陶蕊<sup>1</sup>,贺小星<sup>2</sup>,程远明<sup>3</sup>,周子琪<sup>1</sup>

(1. 东华理工大学测绘工程学院, 江西南昌 330013; 2. 江西理工大学土木与测绘工程学院, 江西赣州 341000;

3. 南昌市城市规划设计研究总院, 江西南昌 330200)

**摘要:**全球导航卫星系统(global navigation satellite system, GNSS)高程时间序列具有非平稳、非线性、含噪声等特点,在深入研究 Prophet 预测模型的基础上,针对 Prophet 预测模型对于趋势信号和周期信号有良好预测效果这一特性,提出一种引入经验模态分解(empirical mode decomposition, EMD)的“降噪—分解—预测”组合 GNSS 高程时间序列预测方法。该方法先将原始时间序列进行 EMD 降噪,再对降噪后的序列进行分解预测,最后重构各分量预测信号为最终预测序列。通过对实测高程数据进行研究,实验结果表明:降噪后信号的平均信噪比为 10.30dB,能量百分比平均为 88.75%;利用所构建的短期预测方法,GNSS 高程时间序列预测结果的均方根误差分别平均提升 26.41% 和 14.88%;平均百分比误差分别平均提升 18.92% 和 7.91%,验证了组合预测方法的有效性及其实用性。

**关键词:**Prophet;经验模态分解;降噪;时间序列预测;组合模型

**中图分类号:**P228 **文献标志码:**A **文章编号:**1001-2486(2023)02-121-10

## Prophet method of GNSS vertical time series prediction considering the influence of noise

LU Tieding<sup>1</sup>, TAO Rui<sup>1</sup>, HE Xiaoxing<sup>2</sup>, CHENG Yuanming<sup>3</sup>, ZHOU Ziqi<sup>1</sup>

(1. Faculty of Geomatics, East China University of Technology, Nanchang 330013, China;

2. School of Civil and Surveying & Mapping Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China;

3. Nanchang Urban Planning & Design Institute, Nanchang 330200, China)

**Abstract:** GNSS (global navigation satellite system) vertical time series have the characteristics of non-stationary, non-linear, and noisy. Based on the in-depth study of the Prophet prediction model, and the good predictive effect of Prophet prediction model on trend signals and periodic signals, a “noise reduction – decomposition – prediction” combined prediction method of GNSS vertical time series that introduces EMD (empirical mode decomposition) was proposed. EMD denoising was performed on the original time series, the denoised series were decomposed and predicted, and the predicted signal of each component was reconstructed into the final predicted series. The measured vertical data was used for research, and results show that the average signal-to-noise ratio of the signal after noise reduction is 10.30 dB, and the average energy percentage is 88.75%; using the short-term prediction method, the root-mean-square errors of GNSS vertical time series prediction results are increased by 26.41% and 14.88% on average, respectively; the average percentage errors are increased by 18.92% and 7.91% on average, respectively, and the effectiveness and practicability of the combined forecasting method are verified.

**Keywords:** Prophet; empirical mode decomposition; noise reduction; time series prediction; combined model

国际全球导航卫星系统(global navigation satellite system, GNSS)服务组织(international GNSS service, IGS)已累积了 20 余年的大地基础数据,这些积累数据有助于大地测量学和地球动力学的持续发展,也为 GNSS 坐标时间序列的研究与分析提供了重要数据来源<sup>[1]</sup>。随着 GNSS 技术的不断发展和完善,GNSS 坐标时间序列的精

准预测,对建筑物变形监测、地壳板块运动、大地气象等研究领域都有着重要意义<sup>[2]</sup>。国内外现有的研究指出,GNSS 坐标时间序列在 N、E、U 三个方向上都有比较明显的趋势性和周期性变化,特别是在 U 方向上呈现非常明显的周期性变化,实际上,GNSS 坐标时间序列叠加了各类“信号”与“噪声”,且在 U 方向上的噪声模型较为复

\* 收稿日期:2021-04-23

基金项目:国家自然科学基金资助项目(42061077,42064001,42104023);国家重点研发计划资助项目(2016YFB0501405);江西省自然科学基金资助项目(2017BAB203032);江西理工大学高层次人才科研启动资助项目(2021205200100564)

作者简介:鲁铁定(1974—),男,陕西富平人,教授,博士,硕士生导师,E-mail:tdlu@whu.edu.cn

杂<sup>[2-5]</sup>。部分学者已将灰度模型、传统自回归滑动平均模型 (autoregressive moving average model, ARMA)、人工神经网络、深度学习引入时序信号预测之中<sup>[6-10]</sup>, 均取得了一定的研究成果, 但此类预测方法都有各自的缺陷: 灰度模型使用广泛但适用性较差; ARMA 模型需要滚动预测保持预测精度; 神经网络模型存在预测过程不稳定、选取参数较为困难等问题。对此, 建立一种自适应、高精度的高程时间序列预测模型较为困难。

针对原始时间序列含噪声且噪声模型丰富的特点及在时序信号预测过程中易受高频噪声影响这一问题, 本文基于 Prophet 预测模型和经验模态分解 (empirical mode decomposition, EMD), 提出一种以 EMD 和连续均方误差 (consecutive mean square errors, CMSE) 理论重构规则相结合的降噪方法对原始时序信号进行降噪处理后, 再对降噪信号进行分解预测的新方法<sup>[11-13]</sup>, 并通过陆态网公布的多组不同跨度的实测信号数据验证本文组合预测方法的有效性和适用性。

## 1 方法与原理

### 1.1 Prophet 预测原理

Taylor 等<sup>[11]</sup>在提出 Prophet 模型的同时还发布了同源的开源软件包, 以促进算法的应用与实现。截至目前, Prophet 模型已经在电力系统、市场流量、经济金融、环境保护等领域有了广泛的应用, 并已经取得较好的应用效果。Prophet 采用广义加法模型来拟合平滑和预测函数, 其分解框架为

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

Prophet 模型将原始时间序列信号自适应分解为 4 个部分: 模拟原始序列趋势项  $g(t)$ 、周期项  $s(t)$ 、特殊突变项  $h(t)$  和噪声项  $\varepsilon_t$ 。 $g(t)$  表示时间序列非线性增长 (非周期项) 部分的变化函数。因在高程时间序列中原始信号非线性且复杂, 趋势项一般采用逻辑回归函数表示, 即

$$g(t) = \frac{c}{1 + e^{[-k(t-m)]}} \quad (2)$$

式中,  $k$  为增长率,  $m$  为位移量,  $c$  为趋势值上限。随着时间  $t$  的增加,  $g(t)$  趋近于  $c$ 。

$s(t)$  的拟合函数以时间序列的傅里叶级数进行构造, 如式 (3) 所示。

$$s(t) = \sum_{n=1}^N \left[ a_n \cos\left(\frac{2\pi n t}{T}\right) + b_n \sin\left(\frac{2\pi n t}{T}\right) \right] \quad (3)$$

式中:  $T$  为时间序列周期, 以周为周期时  $T = 7$ ,  $N = 3$ ; 若以年为周期时  $T = 365.25$ ,  $N = 10$ ;  $2n$  表

示在模型中周期的期望个数。

$h(t)$  通常为假日突变项, 但在 GNSS 坐标时间序列领域中, 不存在因假日或特殊日期引起的突变不规则影响, 故不考虑其对于 GNSS 时间坐标序列预测的影响。 $\varepsilon_t$  为残差项, 且服从正态分布, 可表示为预测到的随机噪声或趋势。

### 1.2 EMD 分解及降噪的基本原理

EMD 分解的基本思想是将原始信号自适应分解为一系列频率由高至低的本征模函数 (intrinsic mode function, IMF) 分量和一个趋势项 (残差项), 详细原理见文献 [12]。而实测 GNSS 信号由低频真实信号与高频噪声信号叠加而成, 故在分解所产生的各分量中, 可将趋势项和邻近的低频 IMF 分量重构为降噪信号, 以达到削弱高频噪声的目的。对于如何在各分量中确定高低频分界分量这一问题, 本文引入 CMSE 确定高频分量与低频分量的噪声分界点<sup>[13]</sup>, 连续均方误差公式如下

$$\begin{aligned} C_{\text{MSE}}(x_p, x_{p+1}) &= \frac{1}{N} \sum_{i=1}^n [x_p(t_i) - x_{p+1}(t_i)]^2 \\ &= \frac{1}{N} \sum_{i=1}^n [\xi_{\text{IMF}_p}(t_i)]^2 \end{aligned} \quad (4)$$

式中:  $N$  为信号长度;  $n$  为 IMF 分量的个数;  $x_p$  为 EMD 所分解产生的模态分量,  $p = 1, 2, \dots, n - 1$ 。

同样式 (4) 也表征了第  $p$  阶 IMF 分量的能量密度, 对于求得连续 IMF 分量之间的均方误差后, 以全局 CMSE 最小值所对应的分量为最佳重构估计信号界限。

EMD 在进行分解时必须满足以下两个条件: 在原始时序信号中, 极值点和过零点的数量最多相差 1 个; 在整个时序信号中, 由局部极大值所构成的上包络线和局部极小值所构成的下包络线的平均值为 0。但在实际时序信号分解过程中, IMF 分量很难满足第二个分解条件, 故设定各分量停止筛选的阈值公式为

$$S_D = \sum_{i=0}^{N-1} \frac{[c_k(t) - c_{k-1}(t)]^2}{c_k^2(t)} \quad (5)$$

式中:  $c_k(t)$ 、 $c_{k-1}(t)$  为分量序列中相邻的序列信号;  $S_D$  为停止筛选阈值, 通常取 0.2 ~ 0.3。

简要 EMD 分解过程如下:

**步骤 1:** 识别计算原始时序信号的极大值、极小值点, 计算上下包络线的均值  $m_1$ , 原始时序信号减去该均值, 从而获取新的时序信号  $c_1(t)$ 。

**步骤 2:** 重复步骤 1, 直到满足阈值条件, 得到各 IMF 分量。

**步骤 3:** 将原始时序信号减去第一个 IMF 分

量,获取新的时序信号,然后重复步骤1与步骤2,当趋势残余项满足要求时停止,最终获取  $n$  个 IMF 分量和一个趋势项分量  $\omega(t)$ 。原始时序信号可表示为

$$x(t) = \sum_{k=1}^n \xi_{\text{IMF}_k} + \omega(t) \quad (6)$$

将原始时序信号分解后,根据 CMSE 理论确定噪声分界分量,取连续均方误差极小值为分界点,又因 GNSS 信号噪声模型丰富,故将分界分量也纳入噪声分量中。分界后对低频分量及趋势项进行重构,得到降噪后的信号,其可表示为

$$x_{\varphi}(t) = \sum_{k=K+1}^n \xi_{\text{IMF}_k} + \omega(t) \quad (7)$$

式中: $x_{\varphi}(t)$ 为降噪后信号; $\xi_{\text{IMF}_k}$ 为分界分量。

### 1.3 组合预测方法流程图

图1为降噪 EMD-Prophet 组合方法流程,图2为用于对比的 EMD-Prophet 分解预测流程。

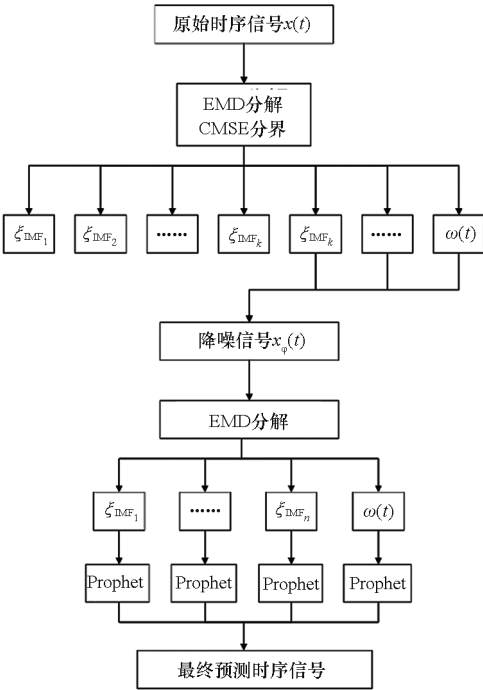


图1 降噪 EMD-Prophet 组合方法流程

Fig.1 Flow chart of noise reduction EMD-Prophet combination method

本文结合 EMD 自适应能力强、降噪效果好的特点,以及 Prophet 对趋势项及周期项预测效果好、设置预测参数简易的优势,建立 EMD-Prophet 的降噪组合预测方法。其具体步骤为

**步骤1:**利用 EMD 对原始时序信号  $x(t)$  进行分解。

**步骤2:**以 CMSE 为分量分界标准,重构低频信号分量和趋势项分量为降噪信号  $x_{\varphi}(t)$ 。

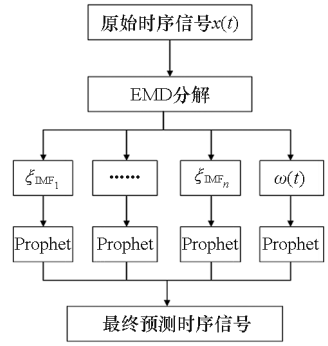


图2 EMD-Prophet 方法流程

Fig.2 Flow chart of EMD-Prophet

**步骤3:**对降噪信号  $x_{\varphi}(t)$  进行 EMD 分解。

**步骤4:**对各分量进行 Prophet 预测,再重构为最终的预测信号。

### 1.4 效果评价指标

为说明组合方法的降噪效果和预测的有效性,利用降噪前后的信噪比( $R_{sn}$ )变化和降噪后序列占原始序列的能量百分比( $E$ )这2个参数评价降噪效果;利用均方根误差 (root mean square error, RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)和残差绝对值均值为参数评价预测精度。5个参数的定义如下<sup>[8,13-14]</sup>:

1)信噪比。

$$R_{sn} = 10 \times \lg \left( \frac{\sum_{n=0}^{N-1} S_n^2}{\sum_{n=0}^{N-1} (S_n - \bar{S}_n)^2} \right) \quad (8)$$

式中, $S_n$ 为原始时间序列信号, $\bar{S}_n$ 为降噪后信号, $N$ 为时序信号长度。若信噪比较高,说明降噪效果较好。

2)能量百分比。

$$E = \int_T |x(t)|^2 dt = \sum_{t=1}^n |x(t)|^2 \quad (9)$$

降噪后序列占原序列的能量百分比  $E_{sn}$  为

$$E_{sn} = E_0/E \quad (10)$$

式中, $E$ 为原始时序信号能量, $E_0$ 为降噪后时序信号能量。 $E_{sn}$ 越大,说明降噪后和原始信号越接近。

3)均方根误差。

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (11)$$

4)平均绝对百分比误差。

$$M_{\text{APE}} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (12)$$

式中,  $x$  为实测值,  $\hat{x}$  为预测值。  $R_{MSE} \in (0, +\infty]$ , 当预测值与实测值完全吻合时等于 0, 即完美模型; 误差越大, 该值越大。  $M_{APE} \in (0, +\infty]$ , 当  $M_{APE}$  为 0% 表示完美模型,  $M_{APE}$  大于 100% 表示劣质模型, 其值越趋近于 0% 则表示模型越好。为直观地反映组合模型各指标的提升效率, 引入精度提升比率与残差绝对值均值来进行说明, 提升率表达式为

$$\delta = \begin{cases} \left(\frac{R_A - R_B}{R_A}\right)\% & \text{负相关} \\ \left(\frac{R_B - R_A}{R_A}\right)\% & \text{正相关} \end{cases} \quad (13)$$

其中,  $\delta$  为提升百分比值,  $R_A$  为对比方法指标,  $R_B$  为本文方法指标。

5) 残差绝对值均值。


$$\gamma = \frac{\sum_{i=1}^n |x_i - \hat{x}_i|}{n} \quad (14)$$

## 2 实验与分析


本文所有实验数据皆由中国地震局 GNSS 数据产品服务台所提供。本文 EMD 降噪实验采用 3 个站点 (BJFS、WUHN、URUM) 的实测公布数据进行研究分析, 时间跨度为 2012—2017 年。在组合预测实验部分中, 选取 BJFS 站数据对 3 种不同跨度的时序信号进行短期预测研究对比分析, 并验证组合预测模型的适用性和有效性。3 种不同跨度实验设计为: 6 组短期实验 (150 d 样本预测 30 d)、3 组中期实验 (335 d 样本预测 30 d)、2 组长期实验 (700 d 样本预测 30 d)。

### 2.1 EMD 降噪

使用上述 EMD 分解降噪方法, 分别对 3 个站点的高程时间序列信号进行降噪分析。图 3 为 3 个站的原始时序信号和所分解的趋势项, 从图 3 中可知, 3 个站点高程方向上的时序信号有明显的周期性变化, URUM 站存在一个上升的趋势特



(b) WUHN



(c) URUM


图 3 原始高程时间序列

Fig. 3 Original vertical time series


征, 而其余 2 站无明显趋势变化, 这一现象可能与站点位置的板块运动有关。BJFS、WUHN、URUM 站的高程趋势项分量与原始信号的皮尔逊相关系数 (U 方向) 分别为 0.684 1、0.603 6、0.753 2。

3 个站点的趋势项分量和原始信号呈显著性相关, 这表明 EMD 可以较好地获取原始信号中的趋势项特征, 但在高程方向上没有呈现高度线性相关特征的主要原因是在高程方向上存在振幅较大的周期项。


图 4 为 3 个站点去除趋势项的时序信号图, 从图中可知, BJFS、URUM 站 U 方向上呈现较为明显的年周期变化, 而 WUHN 站年周期项、季节项变化不明显, 且震荡异常频繁, 并在 2016 年出现较大阶跃现象, 其原因可能与武汉地处江汉平原、长江中游的地质环境相关, 与其所在地壳板块运动复杂, 受多方面因素影响有关<sup>[14]</sup>。




(a) BJFS



(a) BJFS



(b) WUHN



(c) URUM

图4 去趋势项时序信号

Fig.4 Detrend item time series signal

使用 EMD 方法对 3 个站点的原始时序信号进行分解后,依次计算其连续分量之间的 CMSE,其值如表 1~3 所示。

由表 1~3 可知,3 个站点所分解的 IMF 分量有所不同,这反映出 EMD 方法是依据原始时间序列信号的自身特性进行自适应分解的,对同跨度、

表 1 BFJS 站各分量连续均方误差

Tab.1 Continuous mean square error of each component at BFJS station

分量	CMSE	分量	CMSE
$(\xi_{IMF_1}, \xi_{IMF_2})$	$7.5847 \times 10^{-4}$	$(\xi_{IMF_4}, \xi_{IMF_5})$	$14.1753 \times 10^{-4}$
$(\xi_{IMF_2}, \xi_{IMF_3})$	$4.2478 \times 10^{-4}$	$(\xi_{IMF_5}, \xi_{IMF_6})$	$16.5456 \times 10^{-4}$
$(\xi_{IMF_3}, \xi_{IMF_4})$	$2.6434 \times 10^{-4}$	$(\xi_{IMF_6}, \xi_{IMF_7})$	$11.5180 \times 10^{-4}$
$(\xi_{IMF_4}, \xi_{IMF_5})$	$2.0351 \times 10^{-4}$	$(\xi_{IMF_7}, \xi_{IMF_{10}})$	$533.8120 \times 10^{-4}$
$(\xi_{IMF_5}, \xi_{IMF_6})$	$5.2546 \times 10^{-4}$		

表 2 WUHN 站各分量连续均方误差

Tab.2 Continuous mean square error of each component at WUHN station

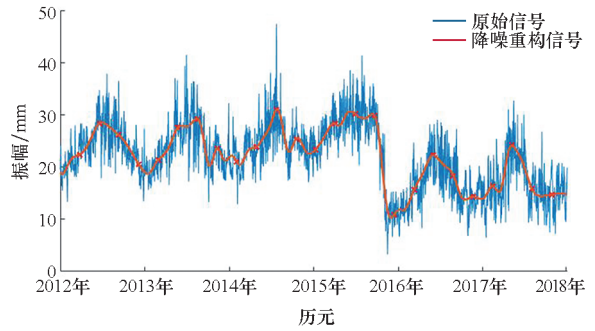
分量	CMSE	分量	CMSE
$(\xi_{IMF_1}, \xi_{IMF_2})$	$56.63340 \times 10^{-4}$	$(\xi_{IMF_7}, \xi_{IMF_8})$	$28.04070 \times 10^{-4}$
$(\xi_{IMF_2}, \xi_{IMF_3})$	$27.16400 \times 10^{-4}$	$(\xi_{IMF_8}, \xi_{IMF_9})$	$101.87190 \times 10^{-4}$
$(\xi_{IMF_3}, \xi_{IMF_4})$	$16.46850 \times 10^{-4}$	$(\xi_{IMF_9}, \xi_{IMF_{10}})$	$63.53974 \times 10^{-4}$
$(\xi_{IMF_4}, \xi_{IMF_5})$	$10.99050 \times 10^{-4}$	$(\xi_{IMF_{10}}, \xi_{IMF_{11}})$	$90.78279 \times 10^{-4}$
$(\xi_{IMF_5}, \xi_{IMF_6})$	$16.32780 \times 10^{-4}$	$(\xi_{IMF_{11}}, \xi_{IMF_{12}})$	$914.14980 \times 10^{-4}$
$(\xi_{IMF_6}, \xi_{IMF_7})$	$24.2051 \times 10^{-4}$		

表 3 URUM 站各分量连续均方误差


Tab.3 Continuous mean square error of each component at URUM station

分量	CMSE	分量	CMSE
$(\xi_{IMF_1}, \xi_{IMF_2})$	$14.2920 \times 10^{-4}$	$(\xi_{IMF_6}, \xi_{IMF_7})$	$9.3901 \times 10^{-4}$
$(\xi_{IMF_2}, \xi_{IMF_3})$	$10.9223 \times 10^{-4}$	$(\xi_{IMF_7}, \xi_{IMF_8})$	$32.3806 \times 10^{-4}$
$(\xi_{IMF_3}, \xi_{IMF_4})$	$8.1001 \times 10^{-4}$	$(\xi_{IMF_8}, \xi_{IMF_9})$	$18.5738 \times 10^{-4}$
$(\xi_{IMF_4}, \xi_{IMF_5})$	$7.0245 \times 10^{-4}$	$(\xi_{IMF_9}, \xi_{IMF_{10}})$	$2115.2240 \times 10^{-4}$
$(\xi_{IMF_5}, \xi_{IMF_6})$	$5.8434 \times 10^{-4}$		


不同站点的信号进行分解的,其结果会有所差异。观察各表中数据,取均方根极小值为分界量, BJFS 和 WUHN 站点以  $(\xi_{IMF_4}, \xi_{IMF_5})$  为分界量进行降噪重构, URUM 站以  $(\xi_{IMF_5}, \xi_{IMF_6})$  为分界量重构。按上述重构方式对各站点的分量进行降噪重构,重构效果如图 5 所示。



(a) BJFS



(b) WUHN



(c) URUM

图5 重构序列

Fig.5 Reconstructing the signal

由图 5 可看出,使用 EMD 降噪可以获得时序信号中的周期项变化,与原始信号有较好的一致性,即周期振荡与原始时序信号振荡趋势保持一致。实验中 3 个站点的周期项振幅值不同,周期长度也不同,由结果发现各站点的周期振幅值并不是一个常数值,这与使用传统方法获取的振幅常值有所不同<sup>[14]</sup>。即使在同一测站中,其周期项的振幅和时间周期也在发生变化。相比于传统方法,本文所获取的周期项可以有效反映其原始信号的运动特征。

表 4 为降噪效果评价参数统计表,由表 4 统计结果可知:

1) 在对原始序列降噪后,3 个站降噪信号的信噪比值都比较高,最高为 12.88 dB,均值为 10.30 dB;降噪后的能量百分比最高为 95.14%,均值为 88.75%,该数据表明本文降噪方法效果明显。

2) 降噪实验结果发现,在 U 方向上,指标参数越大的站点,其降噪后的时序信号呈现更明显的周期振荡变化。

表 4 降噪效果评价参数统计


Tab.4 Statistical table of parameters for evaluating the noise reduction effect

站名	信噪比/dB	能量百分比/%
BJFS(U)	11.42	93.49
WUHN(U)	6.59	77.62
URUM(U)	12.88	95.14
均值(U)	10.30	88.75


### 2.2 预测结果与分析

本节实验采用回溯性预测方式验证预测精度,预测样本数据皆选自 BJFS 站高程时间序列数据(2012—2014 年),为研究不同跨度样本的短期预测效果,本文实验拟设计三个方案:①6 组短期实验以 150 d 样本数据预测 30 d;②3 组中期实验以 335 d 样本数据预测 30 d;③2 组长期实验以 700 d 样本数据预测 30 d。通过比对预测数据来研究组合方法的效果和适应性。


因篇幅所限,各选取 1 组不同跨度的预测实验结果进行展示,其余实验结果均以表格形式展示。图 6 为长期实验中的一组数据分解结果,从图中可以看出,EMD 自适应地将原始信号分解为 7 个模态分量( $\xi_{IMF_n}$ )和 1 个趋势分量( $\omega(t)$ )。图 7 为降噪后的重构信号与高频分量噪声图,从图中可以观察到,EMD 对原始信号进行有效降噪,




(a) 原始信号  
(a) Original signal




(b)  $\xi_{IMF_1}$




(c)  $\xi_{IMF_2}$




(d)  $\xi_{IMF_3}$




(e)  $\xi_{IMF_4}$




(f)  $\xi_{IMF_5}$



(g)  $\xi_{IMF_6}$




(h)  $\xi_{IMF_7}$



(i)  $\omega(t)$


图6 原始信号和 EMD 分解

Fig. 6 Original signal and EMD decomposition



(a) 重构信号

(a) Reconstructed signal chart



(b) 高频分量噪声

(b) High frequency component noise


图7 重构信号和高频分量噪声图

Fig. 7 Reconstructed signal and high frequency component noise chart

降噪信号反映了原始信号的周期振幅,与原始信号有较好的一致性。


图8为预测结果与实测信号的残差对比图。从图中可以发现,在不同跨度的实验中,对原始信号进行降噪后再分解预测的平均残差值最小,预测结果更为准确。其主要原因为 Prophet 预测模型对于时序信号中的周期项、季节项和趋势项有更优的预测效果,同时 Prophet 具备一定的抗粗差特性和鲁棒性,可以有效遏制异常值干扰,可以更准确地对原始时序信号进行预测,并统计全部实验结果,其结果见表5。

由表5数据统计可知,降噪过后分解的预测效果整体优于单一预测模型和分解预测。6组短期实验的结果表明,降噪分解模型相比于其他两




(a) 短期

(a) Short-term



(b) 中期

(b) Medium-term



(c) 长期

(c) Long-term

图8 预测结果残差对比

Fig. 8 Comparison of prediction result residuals

种预测方式,在均方根误差指标上分别提升 19.91% 和 10.95%;在百分比误差指标上分别提升 22.95% 和 7.22%。3组中期实验结果表明,降噪分解模型相比于其他两种预测方式,在均方根误差指标上分别提升 31.44% 和 17.69%;在百分比误差上分别提升 21.34% 和 8.04%。2组长期实验的结果表明,降噪分解模型相比于其他两种预测方式,在均方根误差指标上分别提升 27.98% 和 16.01%;在百分比误差上分别提升 12.48% 和 8.45%。通过实验对比可知,本文所构建的降噪分解再预测的新组合方法更优于单一模型,且具备较强的适用性,也表明本文方法在中长期跨度预测应用中提升效果更为显著。

表 5 预测评价参数统计表

Tab. 5 Statistical of every assessment parameter

BJFS 站	时间跨度	方法	RMSE/mm	MAPE/%	残差绝对值均值/mm
2012 年 1—6 月	短	Prophet	5.52	45.22	4.433
		分解 EMD-Prophet	5.17	28.85	3.910
		降噪分解 EMD-Prophet	4.68	29.88	3.490
2012 年 7—12 月	短	Prophet	3.15	50.56	2.650
		分解 EMD-Prophet	2.33	35.41	1.860
		降噪分解 EMD-Prophet	1.89	31.31	1.540
2013 年 1—6 月	短	Prophet	5.59	37.37	4.910
		分解 EMD-Prophet	5.20	36.22	4.510
		降噪分解 EMD-Prophet	4.57	37.48	3.540
2013 年 7—12 月	短	Prophet	3.80	33.22	3.090
		分解 EMD-Prophet	3.42	31.64	2.630
		降噪分解 EMD-Prophet	3.18	29.27	2.460
2014 年 1—6 月	短	Prophet	6.62	42.20	5.740
		分解 EMD-Prophet	6.02	35.43	4.930
		降噪分解 EMD-Prophet	5.57	25.82	3.880
2014 年 7—12 月	短	Prophet	2.75	42.70	2.200
		分解 EMD-Prophet	2.51	41.13	2.000
		降噪分解 EMD-Prophet	2.05	39.86	1.710
6 组短期平均值		Prophet	4.57	41.88	3.840
		分解 EMD-Prophet	4.11	34.78	3.310
		降噪分解 EMD-Prophet	3.66	32.27	2.750
2012 年	中	Prophet	3.05	43.44	2.500
		分解 EMD-Prophet	2.40	32.94	1.860
		降噪分解 EMD-Prophet	1.87	32.31	1.580
2013 年	中	Prophet	4.04	42.72	3.430
		分解 EMD-Prophet	3.42	40.79	2.750
		降噪分解 EMD-Prophet	2.95	36.85	2.310
2014 年	中	Prophet	3.49	23.79	2.960
		分解 EMD-Prophet	2.99	20.31	2.500
		降噪分解 EMD-Prophet	2.45	17.34	2.060
3 组平均值		Prophet	3.53	36.65	2.960
		分解 EMD-Prophet	2.94	31.35	2.370
		降噪分解 EMD-Prophet	2.42	28.83	1.980
2012—2013 年	长	Prophet	4.13	47.05	3.590
		分解 EMD-Prophet	3.50	47.07	2.890
		降噪分解 EMD-Prophet	2.83	43.39	2.160
2013—2014 年	长	Prophet	3.59	23.79	2.990
		分解 EMD-Prophet	3.12	20.65	2.570
		降噪分解 EMD-Prophet	2.74	18.61	2.270
2 组平均值		Prophet	3.86	35.42	3.290
		分解 EMD-Prophet	3.31	33.86	2.730
		降噪分解 EMD-Prophet	2.78	31.00	2.210



### 3 结论

本文针对 GNSS 高程时间序列信号非线性、非平稳且含噪声的特点,使用 EMD 结合连续均方误差理论进行降噪研究,分析 EMD 方法在不同站点的降噪效果,并对降噪序列进行分解预测研究,通过对比实验结果得出以下结论:

1) EMD 结合连续均方误差理论在 GNSS 高程时序信号降噪中有较好的降噪效果,在对 3 个站点进行分量重构中可以发现,本文实验中的 3 个站点都以  $\xi_{IMF_5}$  左右分量为分界分量,其原因可能与时序信号的构成有关。降噪实验结果的信噪比均值为 10.30 dB,能量百分比均值为 88.75%,结果表明 EMD 结合连续均方误差有较好的降噪效果,可有效削弱噪声影响。

2) EMD-Prophet 降噪分解预测组合方法在 GNSS 高程时序信号中有较好的预测精度,该方法具备较好的抗差性和鲁棒性。从预测结果中可发现,相比于其他两种预测方法,本文方法在 11 组预测结果的均方根误差上分别提升 26.44% 和 14.88%;在百分比误差上分别提升 18.92% 和 7.90%;在绝对值残差平均值上分别提升 31.44% 和 17.48%,表明本文预测精度更优。

本文将 EMD 分解效率高与 Prophet 模型自适应强、预测效果好的特点相结合,并引入连续均方误差理论进行降噪,构建了一种先降噪后分解预测的新组合预测方法,对比了单一的预测方法和分解预测方法在不同跨度样本下的短期预测效果,为 GNSS 高程数据的研究提供了一种新的模式。但 EMD 的分解方法本身存在一些局限性,此类顾及噪声影响再预测的方法也额外增加了一定的工作量,因此,如何构建一种自适应强、计算效率高且预测效果好的新方法还有待更进一步研究。

### 参考文献 (References)

[1] 姜卫平,王锴华,李昭,等. GNSS 坐标时间序列分析理论与方法及展望[J]. 武汉大学学报(信息科学版), 2018, 43(12): 2112-2123.  
JIANG W P, WANG K H, LI Z, et al. Prospect and theory of GNSS coordinate time series analysis[J]. Geomatics and Information Science of Wuhan University, 2018, 43(12): 2112-2123. (in Chinese)

[2] 明锋,杨元喜,曾安敏,等. 中国区域 IGS 站高程时间序列季节性信号及长期趋势分析[J]. 中国科学:地球科

学, 2016, 46(6): 834-844.  
MING F, YANG Y X, ZENG A M, et al. Seasonal signal and long-term trend analysis of elevation time series of regional IGS stations in China[J]. Scientia Sinica (Terrae), 2016, 46(6): 834-844. (in Chinese)

[3] 张恒璟,陆帝,文汉江,等. 一种 IGS 站高程时间序列分析方法[J]. 遥感信息, 2019, 34(6): 1-5.  
ZHANG H J, LU D, WEN H J, et al. Analysis method of IGS station height time series based on CEEMD[J]. Remote Sensing Information, 2019, 34(6): 1-5. (in Chinese)

[4] 苏利娜,丁晓光,张彦芬,等. 陕西连续 GPS 基准站坐标时间序列分析[J]. 大地测量与地球动力学, 2014, 34(5): 106-109, 113.  
SU L N, DING X G, ZHANG Y F, et al. Study on coordinate time series of Shaanxi continuous GPS reference stations[J]. Journal of Geodesy and Geodynamics, 2014, 34(5): 106-109, 113. (in Chinese)

[5] 贺小星,花向红,鲁铁定,等. 时间跨度对 GPS 坐标序列噪声模型及速度估计影响分析[J]. 国防科技大学学报, 2017, 39(6): 12-18.  
HE X X, HUA X H, LU T D, et al. Effect of time span on GPS time series noise model and velocity estimation[J]. Journal of National University of Defense Technology, 2017, 39(6): 12-18. (in Chinese)

[6] 魏玉明,张永志. 基于最小二乘配置法的优化 GM(1, 1) 预测模型及其应用[J]. 大地测量与地球动力学, 2017, 37(3): 297-301.  
WEI Y M, ZHANG Y Z. The optimization GM(1, 1) forecast model and its application based on least squares collocation[J]. Journal of Geodesy and Geodynamics, 2017, 37(3): 297-301. (in Chinese)

[7] 鲁铁定,黄佳伟,鲁春阳,等. 基于 EWT-ARMA 的短期电离层 TEC 预测模型[J]. 大地测量与地球动力学, 2021, 41(4): 331-335, 341.  
LU T D, HUANG J W, LU C Y, et al. Short-term ionospheric TEC prediction model based on EWT-ARMA[J]. Journal of Geodesy and Geodynamics, 2021, 41(4): 331-335, 341. (in Chinese)

[8] 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, 2021, 41(2): 116-121.  
LI W, LU T D, HE X X, et al. Prediction and analysis of GNSS vertical coordinate time series based on prophet-RF model[J]. Journal of Geodesy and Geodynamics, 2021, 41(2): 116-121. (in Chinese)

[9] ACHARYA R, ROY B, SIVARAMAN M R, et al. Prediction of ionospheric total electron content using adaptive neural network with in situ learning algorithm[J]. Advances in Space Research, 2011, 47(1): 115-123.

[10] 李世玺,孙宪坤,尹玲,等. 一种基于混沌理论和 LSTM 的 GPS 高程时间序列预测方法[J]. 导航定位学报, 2020, 8(1): 65-73.  
LI S X, SUN X K, YIN L, et al. A GPS height time series prediction method based on chaos theory and LSTM[J]. Journal of Navigation and Positioning, 2020, 8(1): 65-73.

- (in Chinese)
- [11] TAYLOR S J, LETHAM B. Forecasting at scale [J]. *The American Statistician*, 2018, 72(1): 37–45.
- [12] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903–995.
- [13] KRIM H, TUCKER D, MALLAT S, et al. On denoising and best signal representation [J]. *IEEE Transactions on Information Theory*, 1999, 45(7): 2225–2238.
- [14] 张双成, 何月帆, 李振宇, 等. EMD 用于 GPS 时间序列降噪分析 [J]. *大地测量与地球动力学*, 2017, 37(12): 1248–1252.
- ZHANG S C, HE Y F, LI Z Y, et al. EMD for noise reduction of GPS time series [J]. *Journal of Geodesy and Geodynamics*, 2017, 37(12): 1248–1252. (in Chinese)