

引用格式: 王雨涵, 宋雪丽, 弓剑军. 误差修正的灰色模型在导航卫星钟差预报中的应用[J]. 时间频率学报, 2025, 48(1): 68-78.

误差修正的灰色模型在导航卫星 钟差预报中的应用

王雨涵¹, 宋雪丽¹, 弓剑军²

1. 西安科技大学 理学院, 西安 710600;
2. 中国科学院 国家授时中心, 西安 710600

摘要: 针对单一的灰色模型 (GM (1,1)) 在导航卫星钟差预报中随着时间的增加造成误差累计严重、模型预测精度降低的问题, 提出基于钟差一阶差分数据序列, 建立改进背景值的新陈代谢 GM (1,1) 模型与长短时记忆神经网络模型 (LSTM) 的组合预报模型对卫星钟差预报结果进行改进。使用武汉大学国际全球卫星导航系统服务组织 (IGS) 数据中心的精密钟差数据进行实验、分析, 实验结果证明 NEW_GM (1,1) -LSTM 组合模型与 GM (1,1) -LSTM 组合模型相比, 精度提高了 72%~80%, 与单一的 GM (1,1) 模型相比精度提高了 69%~71%。

关键词: 卫星钟差预报; 灰色模型; 长短时记忆神经网络; 组合模型

DOI: 10.13875/j.issn.1674-0637.2025-01-0068-11

Application of grey model based on error correction in navigation satellite clock bias prediction

WANG Yu-han¹, SONG Xue-li¹, Gong Jian-jun²

1. College of Science, Xi'an University of Science & Technology, Xi'an 710600, China;
2. National Time Service Center, Chinese Academy of Sciences, Xi'an 710600, China

Abstract: The problem that the error accumulation and weak prediction accuracy of the single GM(1,1) model in navigation satellite clock bias prediction is getting serious with the accumulation of time. The paper thus proposed a combination model based on the first-order differences of satellite clocks to establish an improved background value metabolic grey model(GM(1,1)) and a long-short-term memory neural network model(LSTM). Using the precise satellite clock bias data for experiments from the International GNSS Service (IGS), the results of the prediction tests showed that the accuracy of the NEW_GM(1,1)_LSTM combined model would be 54%~74% higher than that of the GM(1,1)_LSTM combined model, and be 60%~75% higher than that of the single GM(1,1) model.

Key words: satellite clock bias prediction; gray model; long-short-term memory network; combined model

在卫星导航系统中，星载原子钟的稳定性与导航电文中的钟差参数密切相关，并决定了实时精密单点定位的精度^[1]，在实时精密单点定位中需要采用钟差预报结果参与计算实现高精度定位^[2]，故研究钟差预报有利于提高参数预报的准确性和可靠性。目前，应用较多的钟差预报模型主要包括：灰色系统（GM（1,1））模型，二次多项式（QP）模型，Kalman 滤波模型^[3-6]。但是单一的模型通常有一定的局限性。GM（1,1）模型随着时间的推移，会不断地有一些随机扰动因素进入系统，使前期数据对后期数据影响逐渐减弱，使得模型预测精度逐渐降低，导致预测误差逐渐增大^[7]；二次多项式模型在预测不规则数据时预测能力较差，且预报随时间推移预测能力减弱；Kalman 滤波模型在非线性的过程中达不到最优的估计效果^[8]。因此，一些专家尝试将 2 个或 3 个单一模型取长补短组合成新的预测模型，以此来提高模型预报的精度。如文献^[9]将灰色模型与自回归（AR）模型相结合，利用灰色模型分离钟差趋势项，然后利用 AR 模型对灰色模型预报的残差建模分析，最后将二者预报的结果相加即可得到最终预报值，其预报精度相较于单一 GM（1,1）模型提高了 23%~59%；如文献^[10]将灰色模型和神经网络组合实现钟差预报，构造了多个不同的 GM（1,1）模型，同时借助神经网络非线性映射能力，将不同的模型进行非线性组合提高钟差预报的精度，结果表明该模型优于经典加权方法的线性组合灰色模型；文献^[11]通过建立一阶差分与长短时记忆（long short-term memory, LSTM）模型相组合的钟差预报模型，其预报精度较直接使用 LSTM 预报模型提高了 76%。

本文考虑到 GM（1,1）模型具有建模所需样本少、适合长期钟差预报，LSTM 模型拟合效果更优且可以降低原子钟内部噪声造成的误差影响^[12]的优点，提出一种基于钟差一阶差分数据序列，建立改进背景值的新陈代谢 GM（1,1）模型与 LSTM 模型组合的导航卫星钟差预报方法。该方法首先对钟差相邻历元间做一阶差分处理，以一阶差分后的值作为灰色模型的建模数据并建立模型，然后利用 LSTM 模型对灰色模型的建模残差进行预

报，最后将二者预报的结果相加即可得到最终预报值。本文以武汉大学国际 GNSS 服务数据中心（International GNSS Service, IGS）提供的采样间隔为 5 min 的精密钟差数据进行分析，探讨不同预报长度可行性和有效性。结果表明，与直接使用 GM（1,1）模型、GM（1,1）_LSTM 的组合模型相比，本文提出的方法能够有效地减小钟差预报中长期误差累积现象，提高预报精度。

1 钟差预报模型

1.1 钟差一阶差分预报原理

文献^[13]提出了对原始相位数据相邻历元求一阶差分的方法，这种处理方法得到的数据在数量级上更小，在一定程度上可以消除原始钟差序列趋势项和系统误差的影响，便于进行异常值的探测和数据预处理。

已知钟差序列记为 $L = \{l(i), i = 1, 2, \dots, n\}$ ，对两个相邻历元作差可得到对应的一阶差分序列数据记为 $\Delta L = \{\Delta l(i), i = 2, 3, \dots, n\}$ ，其中 $\Delta l(i) = l(i) - l(i-1)$ 。用一阶差分后的序列 ΔL 进行建模预报，并预报 $\Delta L(n)$ 对应时刻之后的 $m(m \geq 1)$ 个历元的一阶差分序列 $\Delta L_1 = \{\Delta l(j), j = n+1, n+2, \dots, n+m\}$ ，最后将预报的一次差分序列累加并与第 n 个历元钟差值 $l(n)$ 相加，便可得第 k 个历元的钟差值为

$$l(k) = l(n) + \sum_{n+1}^k \Delta l(k), n+1 \leq k \leq n+m. \quad (1)$$

式（1）中： $\Delta l(k)$ 为预报的第 k 个历元的一次差值。

1.2 改进背景值的新陈代谢 GM（1,1）模型

1.2.1 GM（1,1）模型建立

设 $x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n))$ 为初始数据序列，对此进行一次累加得到新生成的数据序列 $x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n))$ ，其中 $x^{(1)}(m) = \sum_{i=1}^m x^{(0)}(i)$ ， $m = 1, 2, \dots, n$ 。

令 $z^{(1)}$ 为数列 $x^{(1)}$ 的紧邻均值生成数列，得到灰色 GM（1,1）模型为

$$x^{(0)}(k) + az^{(1)}(k) = b. \quad (2)$$

式(2)中: $z^{(1)}(m) = \delta x^{(1)}(m) + (1 - \delta)x^{(1)}(m-1)$, $m = 2, 3, \dots, n$ 且 $\delta = 0.5$, b 表示灰作用量, a 表示发展系数。

引入矩阵形式:

$$u = (a, b)^T, Y = \begin{bmatrix} X^{(0)}(2) \\ X^{(0)}(3) \\ \vdots \\ X^{(0)}(n) \end{bmatrix}, B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix} \quad (3)$$

式(2)可以表示为

$$Y = Bu \quad (4)$$

利用最小二乘法得到参数 a , b 的估计值为

$$\hat{u} = \begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = (B^T B)^{-1} B^T Y \quad (5)$$

将式 $\frac{dx^{(1)}}{dt} + ax^{(1)} = b$ 称作灰色 GM(1,1) 模型白化方程。

取初始值 $\hat{x}^{(1)}(t)|_{t=1} = x^{(0)}(1)$, 求得白化方程的解为

$$\hat{x}^{(1)}(t) = (x^{(0)}(1) - \frac{\hat{a}}{\hat{b}})e^{-\hat{a}(t-1)} + \frac{\hat{a}}{\hat{b}} \quad (6)$$

进一步得到:

$$\hat{x}^{(1)}(m+1) = (1 - e^{\hat{a}}) \left[x^{(0)}(1) - \frac{\hat{a}}{\hat{b}} \right] e^{-\hat{a}m} + \frac{\hat{a}}{\hat{b}}, \quad m = 1, 2, \dots, n-1 \quad (7)$$

1.2.2 背景值的优化

由式(5)可知, GM(1,1) 模型的拟合与预测精度取决于常数 $\hat{a}$ 、 $\hat{b}$, 而 $\hat{a}$ 、 $\hat{b}$ 依赖于原始序列和背景值的构造, 表明背景值是影响误差和预测精度的关键因素之一。故重新构造式(2)中的背景值 $z^{(1)}(k)$ 。

在区间 $[k-1, k]$ 上对 GM(1,1) 模型的白化方程求积分得:

$$\int_{k-1}^k \frac{dx^{(1)}}{dt} + a \int_{k-1}^k x^{(1)} dt = b \quad (8)$$

化简得: $x^{(0)}(k) + a \int_{k-1}^k x^{(1)} dt = b$ 。令

$$z^{(1)}(k) = \int_{k-1}^k x^{(1)} dt \quad (9)$$

设 $x^{(1)}(t) = Be^{At}$, 其中 A , B 为待定常数, $t = 1, 2, \dots, n$, 将其代入式(8)得:

$$z^{(1)}(k) = \int_{k-1}^k Be^{At} dt = \frac{1}{A} [x^{(1)}(k) - x^{(1)}(k-1)] \quad (10)$$

化简得:

$$z^{(1)}(k) = \frac{x^{(1)}(k) - x^{(1)}(k-1)}{\ln x^{(1)}(k) - \ln x^{(1)}(k-1)}, \quad k = 2, 3, \dots, n \quad (11)$$

以上背景值优化理论可参看文献[14]。

1.2.3 新陈代谢方法

在原始的钟差数据序列 $x^{(0)} = (x^{(0)}(i), i = 1, 2, \dots, n)$ 中, 加入新的数据 $x^{(0)}(n+1)$, 该数据采用新构造的背景值预测所得, 同时去掉最老的数据 $x^{(0)}(1)$, 用序列 $(x^{(0)}(2), \dots, x^{(0)}(n), x^{(0)}(n+1))$ 作为新的数据序列去预测下一个值, 一直重复上述步骤直至完成所有的预测目标, 此为改进背景值的新陈代谢 GM(1,1) 模型。关于新陈代谢方法更详细的理论可参看文献[15]。

1.3 LSTM 模型原理

LSTM 是一种循环神经网络(RNN)的变体, 其主要解决了传统 RNN 存在的梯度消失和梯度爆炸的问题, 还可以记住预测值之间的网络状态因此适用于解决长期噪声的钟差数据^[16]。LSTM 包含有 4 个神经网络层, 并且以特殊的方式进行交互。这 4 个神经网络层使得 LSTM 网络包括 4 个输入: 当前时刻输入信息(x_t)、遗忘门(f_t)、输入门(i_t)和输出门(O_t)。各个门上的激活函数为 sigmoid 函数, 其输出范围为 0~1, 用于定义各个门的打开程度, 赋予它去除或者添加信息的能力。

1.4 NEW_GM(1,1)_LSTM 组合模型

本文提出的误差修正的灰色模型是采用 LSTM 模型对改进背景值的新陈代谢 GM(1,1) 模型的预报结果进行修正, 达到误差修正的目的使得预报结果更加精确, 此预报方法记为 NEW_GM(1,1)_LSTM。其主要预报过程如下。

① 对原始钟差数据序列作一阶差分处理, 采用改进 MAD 法对数据进行异常值检测并剔除粗差。

② 采用改进背景值的新陈代谢 GM (1,1) 模型对一阶差分数据序列建模得到建模残差, 随后用改进背景值的新陈代谢 GM (1,1) 模型进行钟差预报。

③ 采用 LSTM 模型对 GM (1,1) 模型的建模残差构建模型并预报。

④ 将改进背景值的新陈代谢 GM (1,1) 模型和 LSTM 模型预报值之和作为最终钟差预报结果, 最后对预报的误差精度进行分析。组合模型的预报流程如图 1 所示。




图 1 组合模型预报流程图

2 实验与结果分析

2.1 数据来源

四大卫星导航系统之一的 GPS 是最早建立的卫星导航系统, 全面投入使用以来, 其各项设备和技术都已经日趋成熟。为了验证本文提出的 NEW_GM (1,1) _LSTM 组合模型预报效果, 实验选取武汉大学国际全球卫星导航系统服务组织 (IGS) 数据中心发布的 2022-01-01/01-03 的精密钟差产品进行实验。由于 GPS 星载原子钟主要是铷钟, 因此本文以 GPS 的铷钟进行钟差预报, 选取 PRN02 (IIR 铷钟)、PRN09 (IIF 铷钟)、PRN17 (IIR-M 铷钟)、PRN18 (IIIA 铷钟) 4 台卫星进行

实验。

2.2 数据预处理

本文采用基于改进中位数绝对偏差法 (median absolute deviation, MAD) 的异常值探测法对钟差的一阶差分数据进行预处理。采用的公式如下:

$$|\Delta l(i)| > m + n \cdot M, \quad (12)$$

$$m = \text{median}\{\Delta l(i)\}, \quad (13)$$

$$M = \text{median}\left\{\left|\frac{\Delta l(i) - m}{0.6745}\right|\right\}. \quad (14)$$

式 (12) 至 (14) 中: $\Delta l(i)$ 为钟差一阶差分序列数据; m 为一阶差分序列的中位数; M 为一阶差分序列偏差绝对值中位数; median 为中位数运算符。钟差一阶差分数据 $|\Delta l(i)|$ 大于一阶差分序列的中位数 (m) 以及中位数 (M) 倍数之和, 则认为该数据是异常值。将异常值进行剔除, 并使用线性内插法补齐剔除历元。 n 的取值大小需要根据需要确定, 本文遵循的原则是: 设置的 n 要保证检测出的异常值个数不能超过建模数据总数的 10%, 这样既可以剔除异常值又能降低异常值对模型预报性能的影响^[17]。

以 PRN18 卫星为例, 选择 IGS 发布的 2022-01-01/01-03 采样间隔为 5 min 的精密钟差数据进行数据预处理, 其结果如图 2 和图 3 所示。从图中可以明显看出, 钟差频率数据存在粗差, 而改进后的 MAD 法能够有效地进行粗差剔除, 预处理后频率数据变得平滑且预处理效果明显。




图 2 PRN18 原始频率数据




图3 PRN18 处理后的频率数据

2.3 方案设计

经过对不同时间长度进行预报及分析, 本文提出的 NEW_GM (1,1) _LSTM 预报模型在 2 d 内的数据长度具有较好的预报效果, 故对于 4 台卫星分别使用 2022-01-01/01-02 的钟差数据进行建模, 以 2 d 建模数据预报接下来 6、12 和 24 h 的钟差数据, 并将预报结果与 2022-01-03 日的 IGS 精密钟差数据进行对比。

方案一: 选用 GM (1,1) 模型预测未来 6、12、24 h 钟差数据。

方案二: 选用 GM (1,1) _LSTM 模型预测未来 6、12、24 h 钟差数据。

方案三: 基于一阶差分法用改进背景值的新陈代谢 GM (1,1) _LSTM 模型来预测未来 6、12、24 h 钟差数据。

方案中 LSTM 神经网络预报模型构造如下。

使用 LSTM 神经网络模型对 GM 残差序列进行训练和预测, 为避免梯度爆炸, 将网络的梯度门限设为 1, 初始的学习率为 0.005, 并设置学习速度的下降率为 0.2, 并对 LSTM 模型的超参数窗

口分割长度 L 和批尺寸大小 B 结合网格搜索和交叉验证进行参数寻优, 最后, 根据寻优结果将窗口跨度 L 设置为 30, 批尺寸大小 B 为 12, 预报随后 6、12、24 h 的钟差值。

2.4 结果分析

原子钟的稳定性会影响钟差预报结果, 通过计算重叠 Allan 方差^[18]对卫星钟的频率稳定性进行分析, 然后以 2022-01-01/01-02 两天的精密钟差数据作为建模数据, 预报时间长度为 6、12、24 h, 分别采用 GM (1,1) 模型、GM (1,1) _LSTM 模型和 NEW_GM (1,1) _LSTM 模型进行预报, 并将预报残差值进行比较。

各卫星钟的稳定性随时间变化趋势如图 4 所示, 千秒稳、万秒稳和天稳值如表 1 所示。从图 4 和表 1 中可以看出, 4 台卫星原子钟的稳定性变化趋势基本一致, 随着时间的增加稳定性在逐步增强, 千秒稳定性和万秒稳定性基本都在 10^{-13} 量级, 日稳定性基本都在 10^{-14} 量级, PRN09 卫星钟的稳定要优于其他 3 台卫星钟, 其中 PRN17 卫星稳定性最差。





图4 GPS 铷钟的重叠 Allan 方差

表 1 GPS 铷钟频率稳定性计算结果


PRN	千秒稳定性/ 10^{-13}	万秒稳定性/ 10^{-13}	日稳定性/ 10^{-14}
G02	9.52	1.16	1.80
G09	9.03	1.06	1.39
G17	10.80	1.34	3.49
G18	7.88	1.07	2.08

图 5 所示为 PRN02 卫星钟采用 3 种预报模型预测未来 6、12、24 h 的钟差数据结果和残差曲线。可以看出，在 6 h 和 12 h 的预报时间范围内，GM (1,1) 模型


和 NEW_GM (1,1) _LSTM 模型的预报结果相近。随着预报时间超过 6 h，GM (1,1) 模型的预报误差逐渐累积加重，而 NEW_GM (1,1) _LSTM 模型误差累计较小。




(a) PRN02 卫星 24 h 预报结果



(b) PRN02 卫星 6 h 预报残差结果



(c) PRN02 卫星 12 h 预报残差结果




(d) PRN02 卫星 24 h 预报残差结果


图 5 PRN02 预报结果统计

图 6 所示为 PRN17 卫星钟采用 3 种预报模型预测未来 6、12、24 h 的钟差数据结果和残差曲线。由图 6 可得：在 6 h 的预报时间范围内，GM (1,1) 模型和 GM (1,1) _LSTM 模型的预报结果相


近。随着预报时间超过 6 h，GM (1,1) _LSTM 模型在预测效果上略逊于 GM (1,1) 模型，而 NEW_GM (1,1) _LSTM 模型在 6、12、24 h 的钟差预报中预报效果均优于其他两种预报模型。




(a) PRN17 卫星 24 h 预报结果



(b) PRN17 卫星 6 h 预报残差结果



(c) PRN17 卫星 12 h 预报残差结果




(d) PRN17 卫星 24 h 预报残差结果


图 6 PRN17 预报结果统计

图 7 和图 8 所示为 PRN09、PRN18 卫星钟采用 3 种预报模型预测未来 6、12、24 h 的钟差数据结果和残差曲线。由图 7 和图 8 可得：随着预


报时间的增加，NEW_GM (1,1) _LSTM 模型依然保持较低的预报误差，而 GM (1,1) 模型和 GM (1,1) _LSTM 模型则呈现出误差累积逐渐加重的趋势。




(a) PRN09 卫星 24 h 预报结果



(b) PRN09 卫星 6 h 预报残差结果




(c) PRN09 卫星 12 h 预报残差结果




(d) PRN09 卫星 24 h 预报残差结果


图 7 PRN09 预报结果统计




(a) PRN18 卫星 24 h 预报结果



(b) PRN18 卫星 6 h 预报残差结果



(c) PRN18 卫星 12 h 预报残差结果



(d) PRN18 卫星 24 h 预报残差结果

图 8 PRN18 预报结果统计

通过以上分析可知, 3 种预报模型随着预报时间增加均存在误差累积的趋势, 但 NEW_GM (1,1) _LSTM 模型在误差累积最小, 能够维持较高的预报准确性。

为了更具体分析各模型的特点, 采用预报误差的极差 (Range) 值对比模型预报的稳定性, 采用预报误差的均方根 (root mean square error, RMSE) 对比模型预报的精度。其中预报误差均方根和极差的计算公式为:

$$T_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i)^2}, \quad (15)$$

$$T_{\text{Range}} = |E_{\max} - E_{\min}|, \quad (16)$$

$$E_i = x_i - \hat{x}_i. \quad (17)$$

式 (15) 至 (17) 中: E_i 为预报误差, $\hat{x}_i$ 、 x_i 为 i 时刻的 IGS 精密钟差预报值和观测钟差值, n 为预报历元个数。

表 2 和图 9、图 10 为各卫星采用不同预报模型进行不同预报时长的结果统计。由表 2 和图 9 可得到如下结果。

① 改进的组合模型预测效果优于传统 GM (1,1) 模型和 GM (1,1) _LSTM 模型。同时预报时长与模型预报残差呈现正相关, 即预报时长增加 3 种模型的预报残差随之增加。在 6、12、24 h 的钟差预报中, GM (1,1) 模型的均方根误差分别为 0.81、1.69、3.24 ns; GM (1,1) _LSTM 模型的均方根误差分别为 1.58、2.06、2.95 ns; NEW_GM (1,1) _LSTM 模型的均方根误差分别为 0.42、0.57、0.58 ns, 与 GM (1,1) 模型精度相比提高了 71.68%、69.46%、70.80%, 与 GM (1,1) _LSTM 模型精度相比提高了 73.20%、72.36%、80.48%。其中, NEW_GM (1,1) _LSTM 模型在 4 台卫星钟差预报中误差均在 1 ns 之内, 最小的为 0.21 ns, 平均精度达到亚纳秒级别。

② 通过对比 3 个模型的预报效果发现, 不同模型对原子钟预报效果存在差异, 同种模型对不同原子钟预报效果也存在差异。卫星类型为 IIR-M 的 PRN17 号卫星预报效果最差, 6、12、24 h 的均方根误差平均值分别为 2.26、3.12、3.74 ns, 结合稳定性分析得, PRN17 卫星日稳定性较差, 导致预报结果略差, 这可能是受卫星所处环境、发射时间以及设备老化的影响; 卫星类型为 IIF 的 PRN09 号卫星预报效果最好, 6、12、24 h 的均方根误差平均值分别为 0.49、0.55、0.85 ns。


③ 由预报残差变化曲线和 RMSE 值对比可知, GM (1,1) _LSTM 模型的预报结果趋势与 GM (1,1) 模型相似, 但随着预报时间的增加两种模型的残差曲线波动幅度较大, 而 NEW_GM (1,1) _LSTM

模型残差曲线变化较为平缓。NEW_GM (1,1) _LSTM 模型较单一 GM (1,1) 模型和 GM (1,1) _LSTM 模型预报结果的稳定性更高。对比 3 种模型 Range 值可知, 在 6h 预报时长内, NEW_GM (1,1) _LSTM 模型的误差波动范围大于单一 GM (1,1) 模型; 但是在 12、24h 预报时间内, NEW_GM (1,1) _LSTM 模型的误差波动范围均小于其他两种模型。当拟合 2 d 数据预测未来 12、24 h 钟差时, NEW_GM (1,1) _LSTM 模型的预测稳定性与 GM (1,1) 和 GM (1,1) _LSTM 模型相比分别提高 15%、50% 和 32%、56%。


故采用本文提出的 NEW_GM (1,1) _LSTM 方法, 钟差预报的精度和稳定性均有显著提高。

表 2 3 种模型评定结果


卫星	预报时长 /h	不同模型预报结果/ns						平均值/ns	
		GM (1,1)		GM (1,1) _LSTM		NEW_GM (1,1) _LSTM		T_{Range}	T_{RMSE}
		T_{Range}	T_{RMSE}	T_{Range}	T_{RMSE}	T_{Range}	T_{RMSE}		
PRN02	6	0.70	0.33	1.33	0.60	1.08	0.40	1.04	0.44
	12	1.17	0.50	1.81	0.90	1.24	0.52	1.41	0.64
	24	2.11	1.05	2.75	1.48	1.75	0.64	2.20	1.06
PRN09	6	0.39	0.77	0.39	0.48	0.25	0.21	0.34	0.49
	12	0.56	0.83	0.55	0.54	0.48	0.28	0.53	0.55
	24	1.58	1.30	1.57	1.04	0.66	0.22	1.27	0.85
PRN17	6	1.11	3.09	2.39	3.20	1.86	0.49	1.78	2.26
	12	3.03	3.97	4.25	4.39	3.23	1.00	3.50	3.12
	24	4.30	4.89	5.54	5.43	3.23	0.88	4.36	3.74
PRN18	6	1.05	1.78	0.88	2.03	0.50	0.60	0.81	1.47
	12	2.00	2.14	1.83	2.39	0.77	0.47	1.53	1.67
	24	4.95	3.62	4.78	3.85	0.83	0.56	3.52	2.68



(a) 预测 6 h



(b) 预测 12 h



(c) 预测 24 h

图 9 不同预测时间的 RMSE




图 10 不同预测时间的 Range

3 结语

本文针对单一 GM (1,1) 预报模型在卫星钟差预报中存在误差累积的问题, 提出了一种基于一阶差分法的改进背景值的新陈代谢 GM (1,1) _LSTM 组合模型, 该模型可以有效降低预报模型的误差累积。实验结果显示本文提出的模型的精度、稳定度均高于单一模型和 GM (1,1) _LSTM 组合模型, 具体如下。

① 在卫星钟差预报中, 本文提出的 NEW_GM (1,1) _LSTM 模型预报精度均优于 GM (1,1) 模型、GM (1,1) _LSTM 模型。对于 6、12、24 h 的钟差预报, NEW_GM (1,1) _LSTM 模型的均方根误差分别为 0.42、0.57、0.58 ns, 平均精度达到亚纳秒级别。

② 对于 6、12、24 h 的钟差预报, 本文提出的 NEW_GM (1,1) _LSTM 模型 GM (1,1) 模型在预测精度 RMSE 上分别提高了 71.68%、69.46%、70.80%; 较 GM (1,1) _LSTM 模型在预测精度 RMSE 上分别提高了 73.20%、72.36%、80.48%。

③ 对于 6、12、24 h 的钟差预报, 本文提出的 NEW_GM (1,1) _LSTM 模型较 GM (1,1) _LSTM 模型在预测稳定度 Range 上分别提高了 26.14%、32.20%、55.84%。

因此本文提出的 NEW_GM (1,1) _LSTM 模型能够有效抑制钟差预报过程中预报误差随时间积累的现象, 进一步提高了模型的预报性能和预报精度。故本文提出的方法经理论和预报试验分析验证, 表明是有效的和可行的, 可以作为一

种导航卫星钟差预报的方法, 为实际工程中的导航卫星钟差预报提供参考价值。

参考文献:

- [1] 赵金霞. 一种改进的粒子群优化超快速 BDS 卫星钟差预报方法[J]. 导航定位学报, 2023, 11(6): 156-163.
- [2] 郑作亚, 党亚民, 卢秀山, 等. 附有周期项的预报模型及其在 GPS 卫星钟差预报中的应用研究[J]. 天文学报, 2010, 51(1): 95-102.
- [3] LIANG Y, REN C, YANG X, et al. A grey model based on first differences in the application of satellite clock bias prediction[J]. Chinese Astronomy and Astrophysics, 2016, 40(1): 79-93.
- [4] 王志浩, 胡永辉, 侯雷, 等. 二次多项式模型和灰色理论模型在接收机钟差预报中的应用和比较[J]. 时间频率学报, 2014, 37(3): 157-163.
- [5] 宋会杰, 董绍武, 屈俐俐, 等. 基于 Sage 窗的自适应 Kalman 滤波用于钟差预报研究[J]. 仪器仪表学报, 2017, 38(7): 1809-1816.
- [6] HUANG G, ZHANG Q. Real-time estimation of satellite clock offset using adaptively robust Kalman filter with classified adaptive factors[J]. GPS Solutions, 2012, 16(4): 531-539.
- [7] 牛树华, 于焯, 黄默, 等. 基于误差修正的 GM(1,1) 导航卫星钟差预报算法[J]. 舰船电子对抗, 2019, 42(4): 81-86.
- [8] 高喆, 屈俐俐, 董绍武, 等. 氢原子钟的钟差预报方法研究[J]. 时间频率学报, 2017, 40(2): 73-79.
- [9] 郭忠臣, 宋明洋, 孙朋, 等. 灰色模型与自回归模型组合在钟差短期预报中的应用研究[J]. 西昌学院学报(自然

- 科学版), 2020, 34(4): 53-57.
- [10] 雷雨, 赵丹宁, 高玉平. 基于灰色系统和神经网络的钟差预报[J]. 时间频率学报, 2013, 36(3): 156-163.
- [11] 吉长东, 朱锦帅, 黎虎, 等. BDS 卫星钟差短期预报的 LSTM 算法[J]. 导航定位学报, 2021, 9(1): 44-52.
- [12] 王锐, 弓剑军, 杜洪强, 等. 基于长短时记忆神经网络 (LSTM) 的钟差预报算法[J]. 宇航计测技术, 2022, 42(5): 57-62.
- [13] 王宇谱, 薛申辉, 王威, 等. 基于一次差分预报原理的常用钟差预报模型效果分析[J]. 大地测量与地球动力学, 2021, 41(4): 336-341.
- [14] 罗党, 刘思峰, 党耀国. 灰色模型 GM(1,1) 优化[J]. 中国工程科学, 2003(8): 50-53.
- [15] 刘思峰, 党耀国, 方志耕, 等. 灰色系统理论及其应用[M]. 北京: 科学出版社, 2010.
- [16] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772-784.
- [17] 王宇谱, 吕志平, 陈正生, 等. 一种新的钟差预处理方法及在 WNN 钟差中长期预报中的应用[J]. 武汉大学学报(信息科学版), 2016, 41(3): 373-379.
- [18] HUANG G, ZHANG Q, LI H, et al. Quality variation of GPS satellite clocks on-orbit using IGS clock products[J]. Advances in Space Research, 2013, 51 (6): 978-987.