

沈家庆,胡茂楠,许磊,等.改进CNN-BiLSTM-Attention模型的GPS时钟误差预测算法[J].辽宁工程技术大学学报(自然科学版),2025,44(6):753-760.DOI:10.11956/j.issn.1008-0562.20250024

SHEN Jiaqing,HU Maonan,XU Lei,et al.Improved GPS clock bias prediction algorithm based on CNN-BiLSTM-Attention model[J].Journal of Liaoning Technical University(Natural Science),2025,44(6):753-760.DOI:10.11956/j.issn.1008-0562.20250024

改进CNN-BiLSTM-Attention模型的GPS时钟误差预测算法

沈家庆¹,胡茂楠¹,许磊¹,胡飞²,邢晓晴¹,钟勉^{1,3*}

(1. 中国民用航空飞行学院 航空电子电气学院,四川 广汉 618307;2. 中国民用航空飞行学院 遂宁分院,四川 遂宁 629001;3. 民航飞行技术与飞行安全重点实验室,四川 广汉 618307)

摘要:针对民航GPS时钟误差易受干扰和欺骗信号影响的问题,提出一种改进的CNN-BiLSTM-Attention预测模型。采用动态中位数绝对偏差法剔除时钟误差的单差序列异常值,并利用三次样条插值法修复数据。基于原始数据提取关键特征,通过消融实验分别评估CNN-BiLSTM-Attention预测模型在有、无干扰,以及短期(1 h)、中期(6 h)和长期(12 h)的抗干扰能力。研究表明:与ARIMA相比,CNN-BiLSTM-Attention预测模型的剩余预测残差提升49.2%;与XGBoost模型相比,平均绝对值降低53.3%;与ELM模型相比,均方根误差下降51.2%, R^2 提升34.7%。该模型在复杂环境下预测精度和稳定性较高,能显著提升GPS时钟误差的预测性能,为高精度GPS抗干扰定位提供了新思路。

关键词: GPS时钟误差; GPS定位; 单差序列; 抗干扰; BiLSTM; 消融实验

中图分类号: TN927

文献标志码: A

文章编号: 1008-0562(2025)06-0753-08

Improved GPS clock bias prediction algorithm based on CNN-BiLSTM-Attention model

SHEN Jiaqing¹, HU Maonan¹, XU Lei¹, HU Fei², XING Xiaoqing¹, ZHONG Mian^{1,3*}

(1. College of Aviation Electronics and Electrical, Civil Aviation Flight University of China, Guanghan 618307, China; 2. Suining Branch, Civil Aviation Flight University of China, Suining 629001, China; 3. Key Laboratory of Flight Technology and Flight Safety, CAAC, Guanghan 618307, China)

Abstract: Aiming at the problem that civil aviation GPS clock error is susceptible to interference and deception signals, an improved CNN-BiLSTM-Attention prediction model is proposed. The dynamic median absolute deviation method is used to eliminate the single-difference sequence outliers of the clock error, and the cubic spline interpolation method is used to repair the data. Based on the key features extracted from the original data, the anti-interference ability of the CNN-BiLSTM-Attention prediction model with and without interference, as well as short-term (1 h), medium-term (6 h) and long-term (12 h) were evaluated by ablation experiments. The results show that compared with ARIMA, the residual prediction deviation of CNN-BiLSTM-Attention prediction model is increased by 49.2%; compared with the XGBoost model, the mean absolute error is reduced by 53.3%; compared with the ELM model, root mean square error decreased by 51.2% and R^2 increased by 34.7%. The model has high prediction accuracy and stability in complex environments, and can significantly improve the prediction performance of GPS clock error, which provides a new approach for high-precision GPS anti-jamming positioning.

Keywords: GPS clock bias; GPS positioning; single difference sequence; anti-interference; BiLSTM; ablation experiments

收稿日期: 2025-01-14 修回日期: 2025-05-13 接受日期: 2025-05-20 责任编辑: 焦丽

基金项目: 民航飞行技术与飞行安全重点实验室研究项目(FZ2022ZZ03; FZ2022ZX46)

作者简介: 沈家庆(1978-),男,安徽蚌埠人,硕士,副教授,主要从事航空电子方面的研究。E-mail: 13881017769@163.com

通信作者: 钟勉(1984-),男,四川成都人,博士,副教授,主要从事GPS干扰源排查方面的研究。E-mail: mianzhong@cafuc.edu.cn

0 引言

卫星时钟误差是星载原子钟的时间指示与系统标准时间之间的差值,该偏差通过地面操作控制系统进行测量^[1],其反映的星载时钟随机特性是定位精度的主要误差来源之一。以GPS系统为例,GPS信号在传播过程中易受复杂环境的影响,例如信号阻塞、多径效应、干扰及欺骗等,这些因素会显著降低接收机的定位精度并影响干扰识别的准确性^[2]。因此,为满足GPS对高精度和实时定位的需求,精确预测卫星时钟误差尤为重要。

深度学习被广泛引入卫星时钟误差预测中,用以提升低功耗接收机的定位精度。研究主要集中于循环神经网络(LSTM、GRU)、卷积神经网络(CNN),以及自注意力机制等模型^[3-4]。ZHANG等^[5]设计了融合LSTM单元的深度递归Q网络(DRQN)架构。LSTM捕捉信道与干扰的时序特征,展平后通过全连接层输出Q值,并生成抗干扰策略,但难以对抗多源复杂干扰场景。XIE等^[6]设计了一种双天线输入的LSTM网络,并构建专用损失函数,利用空间相关性非线性地估计并消除干扰信号。LI等^[7]针对导航扫频干扰对传统时域自适应滤波性能的严重破坏,提出在滤波权向量中引入“定时重置”机制,改善扫频干扰条件下的抗干扰性能。WANG等^[8]提出基于单差序列及小波神经网络模型(WNN)进行时钟误差的预测,该方法能够降低离群点的影响,进一步提升WNN模型的预测效果。ZHANG等^[9]基于时间序列ARMA模型和贝叶斯统计理论,提出一种精确预测卫星时钟偏差并检测卫星时钟偏差历史序列中异常值的方法。HE等^[10]使用LSTM模型预测第三代北斗导航的时钟误差,与自回归积分移动平均(ARIMA)和二次多项式(QP)模型相比,预测精度更高。以上研究表明,单一模型结构对复杂噪声建模能力有限。因此,CAI等^[11]针对北斗卫星提出基于LSTM自注意力机制的混合模型,旨在平衡全局注意力与局部特征的捕获能力。JIN等^[12]构建了结合半参数调整模型和稀疏自注意力网络的SLFAI模型,优化了注意力机制和参数搜索,显著

提高了预测效率和精度。SONG等^[13]对比了BPNN、WNN、LSTM和GRU等模型,引入周期项进行短期预测,结果表明混合小波网络在短期预测中表现稳定。与CNN和LSTM模型的对比分析中,该方法表现优异,但处理较长时间序列模型时的可靠性仍有待提升。HUANG等^[14]提出一种基于循环项和随机项建模的监督学习LSTM网络模型(SL-LSTM),该方法虽然在长期预测模型上表现良好,但在短期预测方面未能展现明显优势。同时,现有的预测模型较少考虑欺骗及干扰攻击下信号预测的稳定性,其抗干扰能力有待验证,且存在长期预测精度不足的局限,需进一步加大模型在复杂环境下的研究。

针对上述问题,提出基于动态中位数绝对偏差和三次样条插值的异常值预处理方法,将动态中位数绝对偏差与三次样条插值相结合,应用于GPS时钟误差单差序列的异常值检测与修复,有效剔除异常值,保障后续模型训练的数据质量。构建CNN-BiLSTM-Attention架构的多尺度融合预测模型。该模型融合CNN模块、BiLSTM模块、Attention机制,显著提升对复杂干扰环境下时钟误差与预测性能。将CNN-BiLSTM-Attention架构的多尺度融合预测模型与LSTM模型进行对比,验证其长时序及抗干扰的优势。

1 数据预处理

1.1 时钟误差单差序列

原始采集的GPS时钟误差数据受噪声、干扰以及传播误差的影响,包含异常数据和随趋势项变化数据^[9]。时钟误差数据相邻历元的两个时间序列数据变化较小,异常数据不易被发现。而时钟误差的单差序列能直观表示相邻历元间的变化趋势,可以突出并识别出时钟误差中的异常点,如图1(a)所示。因此,模型预测之前对原始数据进行预处理,得到单差序列数据,以便检测并去除数据中的异常值。消除单差序列中异常值后,对单差序列的趋势项进行二次多项式拟合,获得误差更小的数据序列^[15],如图1(b)所示。




图1 单差序列预处理结果

Fig.1 preprocessing result of single difference sequence

1.2 动态中位数绝对偏差数据处理

动态中位数绝对偏差 (dynamic median absolute deviation, DMAD) β_{DMAD} 通过计算单差序列中每个数据点的绝对偏差值,并根据中位数计算 β_{DMAD} ,基于每个数据点与中位数的偏差是否超过设定的阈值来识别异常值并标记。在设置阈值系数时,原则上保证检测出的异常值不超过数据总量的5%,避免对有效数据的误删。一旦检测到异常值,使用三次样条插值法替换异常值,利用相邻的非异常值生成平滑、连续的序列,减少异常值对模型预测的影响。

设原始时钟误差数据为 $\mathbf{X} = (X_1, X_2, \dots, X_n)$, 其中, X_i 表示第 i 个历元的时钟误差。对 $\mathbf{X}$ 进行一阶差分,生成单差序列 $\mathbf{D} = (D_1, D_2, \dots, D_n)$,以突出局部异常点。单差序列中包含随趋势项变化数据,这些趋势项会对离群值检测产生干扰,一阶差分公式为

$$D_i = X_{i+1} - X_i, \quad (1)$$

第 i 个历元的拟合趋势项可表示为

$$T_i = a_0 + a_1 i + a_2 i^2 + \dots + a_k i^m, \quad (2)$$

式中, m 为多项式阶数。

趋势项被消除后,在单差序列的基础上,结合DMAD方法检测异常值,进行动态中位数更新,根据趋势变化动态调整单差中位数 M_r ,并对自适应阈值进行调整,动态设定检测阈值。

DMAD方法的计算式为

$$R_i = D_i - T_i, \quad (3)$$

$$\beta_{\text{DMAD}} = M_r(|R_i - M_r|), \quad (4)$$

$$k = \lambda \cdot \beta_{\text{DMAD}}, \quad (5)$$

式(3)~式(5)中: k 为检测阈值; λ 的取值范围为[1.5,3],确保检测出的异常值占比小于5%。

若式(5)中, $k < |R_i - M_r|$,则认为 R_i 是异常点。对异常点采用三次样条插值法进行修复。设原始单差序列节点为 $(t_i, \Delta d_i)$, 其中, t_i 为第 i 个历元时间, Δd_i 为对应的时钟误差单差,插值系数通过相邻的非异常点计算得到。

每个节点处,插值函数需通过给定点,保持插值一致性,同时保证一阶二阶导数连续,确保两端的曲率为0,即

$$S_i(t_i) = \Delta d_i, S_i(t_{i+1}) = \Delta d_{i+1}, \quad (6)$$

$$S'_i(t_{i+1}) = S'_{i+1}(t_{i+1}), \quad (7)$$

$$S''_i(t_{i+1}) = S''_{i+1}(t_{i+1}), \quad (8)$$

$$S''_0(t_0) = 0, S''_{n-1}(t_n) = 0. \quad (9)$$

对于任意 $t \in [t_i, t_{i+1}]$,插值结果可由对应的 $S_i(t)$ 给出,以精确填补序列中的缺失或异常值。

使用均方误差 (MSE) 作为损失函数,单差序列预处理见图1。可见,通过融合多项式趋势建模和DMAD预处理,单差序列处理后的数据与理想的时钟误差值更加接近,预处理后的损失函数曲线更加平滑,预测误差更小。

1.3 数据归一化

为消除不同维度数据间的差异,在将数据输入预测网络前,采用式(10)对数据归一化处理,结果见表1。

第 i 个采样点原始值 X_i 归一化后为

$$X_i^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}, \quad (10)$$

式中, $X_{\max}$ 、 $X_{\min}$ 分别为原始值中的最大和最小值。

表1 数据归一化结果

数据	归一化前	归一化后
可见卫星个数	28~31	0.33~0.67
时钟漂移	212~213 ns	0.99~1
经度	102.697°E~102.705°E	0.22~0.24
纬度	25.049°N~25.057°N	0.99~1
高度	$1.89 \times 10^6 \sim 1.90 \times 10^6$ m	0.19~0.20
时钟误差	$1.417 \times 10^4 \sim 1.425 \times 10^4$ ns	0~0.001 1

1.4 隐层单元数选择

模型隐层单元数需平衡网络表达能力与训练复杂度:单元数越多,模型学习能力越强,但计算量增加、收敛速度减慢,还有可能出现过拟合,导致泛化能力下降;单元数过少,网络简洁、训练更快,但表达能力可能不足,预测精度较难提升。因此,在不影响模型性能的前提下,兼顾计算效率与预测准确度,选择模型隐层的单元数。为评估其影响,计算隐藏层神经元数在2~16变化时的GPS钟差预测误差,见图2。由图2可见,隐层单元数为12时,预测精度最优,且训练效率相对较高,因此选择隐层单元数为12。




图2 隐藏层单元数与钟差预测MSE的关系

Fig.2 relationship between the number of hidden layer neurons and the MSE of clock error prediction

2 模型设计

2.1 CNN-BiLSTM-Attention 模型架构

CNN-BiLSTM-Attention 模型框架见图 3。该模型利用 CNN 从时序数据中提取局部特征, BiLSTM

处理前向和反向输入中获得的特征数据, Attention 模块进一步增强全局依赖特征, 捕获对结果有重大影响特征, 实现对 GPS 时钟误差数据的高精度预测^[16]。




图 3 CNN-BiLSTM-Attention 模型框架

Fig.3 CNN-BiLSTM-Attention model framework

2.2 卷积神经网络(CNN)模块

CNN 通过卷积核有效捕获局部非线性特征^[17]。其中, 卷积层使用一维卷积核提取时钟误差的局部特征, 池化层通过最大池化操作降低特征维度, 保留关键信息, 全连接层将提取的局部和全局特征整合并映射到最终输出。第 l 层卷积后的特征可表示为

$$f_i^{(l)} = \sigma(W_{\text{conv}}^{(l)} * f_{i-1}^{(l)} + b_{\text{conv}}^{(l)}), \quad (11)$$

$$p_i^{(l)} = \max \text{pool}(f_i^{(l)}), \quad (12)$$

式 (11)、式 (12) 中: $W_{\text{conv}}^{(l)}$ 和 $b_{\text{conv}}^{(l)}$ 为权重和偏置; $*$ 为卷积操作; $\sigma(\cdot)$ 为激活函数。

2.3 双向长短期记忆网络(BiLSTM)模块

传统 LSTM 模型是时间序列数据预测模型, 由遗忘门、输入门和输出门组成^[18]。遗忘门用 sigmoid 激活函数生成遗忘因子, 决定存储单元丢失哪些信息; 输入门控制新信息流入记忆单元, 结合 sigmoid 和 tanh 函数更新细胞状态。输出门 (output gate) 控制从存储单元到网络输出的信息流, 通过 sigmoid 和 tanh 函数生成单元的最终输出, 同时捕获序列数据中的长期依赖性。

双向长短期记忆网络 (BiLSTM) 在传统 LSTM 的基础上, 构建前向和后向的双层结构, 通过融合双向时间特征, 更全面地捕获时间序列数据的依赖关系, 显著提升对复杂 GPS 时钟误差数据的预测水平。

前向 LSTM 计算从时间步 1 到 T 的隐藏状态, 后向 LSTM 计算从时间步 T 到 1 的隐藏状态, 最终将双向隐藏状态结合, 生成双向时间特征, 公式为

$$h_t^{\text{fwd}} = \text{LSTM}(X_t, h_{t-1}^{\text{fwd}}), \quad (13)$$

$$h_t^{\text{bwd}} = \text{LSTM}(X_t, h_{t+1}^{\text{bwd}}), \quad (14)$$

$$h_t = (h_t^{\text{bwd}}, h_t^{\text{fwd}}), \quad (15)$$

式 (13) ~ 式 (15) 中: h_t^{fwd} 为前向 LSTM 在时间步 t 的隐藏状态, 用于捕捉前向时间依赖关系; h_t^{bwd} 为后向 LSTM 在时间步 t 的隐藏状态, 用于捕捉后向时间依赖关系; h_t 为双向 LSTM 在时间步 t 的最终输出状态。

2.4 Attention 机制

引入 Attention 机制, 构建 CNN-BiLSTM-Attention 模型, 其整体结构见图 4。




图 4 CNN-BiLSTM-Attention 网络结构

Fig.4 CNN-BiLSTM-Attention network structure

图4中, Attention机制以BiLSTM层输出的隐藏状态作为输入, 根据特征的相关性动态分配权重, 增强对关键特征的关注度, 减弱次要特征的干扰。对于含 T 个时间步的双向特征序列, 通过前馈网络, 计算各时间步 i 的计算注意力分数 e_i , 采用Softmax函数对 e_i 进行归一化, 生成权重向量 α_i 。将 α_i 与对应的隐藏状态逐元素相乘, 并对所有时间步的加权隐藏状态求和, 得到综合时序序列 c 。

为融合时序上下文, 将 c 与BiLSTM最后一个时间步的隐藏状态 h_T 拼接后, 输入到全连接层得到最终预测。其核心计算公式为

$$e_i = \mathbf{v}^T \tanh(\mathbf{W}_h \mathbf{h}_i + \mathbf{b}_h), \quad (16)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^T \exp(e_j)}, \quad (17)$$

$$\sum_{i=1}^T \alpha_i = 1, \quad (18)$$

$$c = \sum_{i=1}^T \alpha_i h_i, \quad (19)$$

$$o = \phi(\mathbf{W}_o(c; h_T) + \mathbf{b}_o), \quad (20)$$

式(16)~式(20)中: $\mathbf{v}$ 、 $\mathbf{W}_h$ 、 $\mathbf{b}_h$ 为训练参数; h_i 为双向特征序列; $\phi(\cdot)$ 为激活函数; $\mathbf{W}_o$ 、 $\mathbf{b}_o$ 为映射参数。

2.5 预测流程

CNN-BiLSTM-Attention模型的计算流程见图5, 该流程包括数据预处理、预测和模型评估3个阶段。




图5 模型整体流程图

Fig.5 overall flow chart of the model

3 实验分析

采用云南大学利用GNSS监测系统采集的数据

集, 选取GPS L1C/A波段的时钟误差观测时序序列数据, 输入数据包括可见卫星数目、时钟漂移、经度、纬度、高度等, 输出为时钟误差数据。数据集包含接收机三种场景下的观测结果: 正常状态、受商业干扰机影响状态、SDR HackRF One欺骗状态^[19]。将数据集按照7:3的比例分为训练集和测试集, 进一步划分1 h、6 h和12 h三类时间窗口进行短期、中期和长期预测, 并对模型预测及抗干扰性能进行对比研究。

评价指标包括均方根误差 E_{RMSE} 、平均绝对误差 E_{MAE} 、决定系数 R^2 和剩余预测残差 E_{RPD} , 计算式为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \quad (21)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (23)$$

$$E_{\text{RPD}} = \frac{\sigma}{E_{\text{RMSE}}}, \quad (24)$$

式(21)~式(24)中: y_i 为第 i 个真实值; $\hat{y}_i$ 为第 i 个预测值; $\bar{y}$ 为真实值的平均值; n 为样本总数; σ 为预测误差的标准差。

3.1 消融实验

在无干扰情况下, 进行消融实验。将CNN-BiLSTM-Attention模型(本文模型)与LSTM模型、CNN-LSTM模型、CNN-BiLSTM模型进行对比, 计算各模型的评价指标, 结果见表2。由表2可见, 与LSTM模型相比, CNN-LSTM模型在短期(1 h)、中期(6 h)和长期(12 h)的预测中, E_{RMSE} 分别降低了7.9%、24.5%和23.6%, E_{MAE} 分别降低12.2%、30.6%、46.6%, R^2 值和 E_{RPD} 均有提升, 可以看出引入CNN增强了模型的多维特征提取能力。与CNN-LSTM模型相比, CNN-BiLSTM模型的 E_{RMSE} 分别降低7.3%、20.7%和34.0%, 表明双向LSTM依赖建模显著增强了对中长期趋势的捕捉。与CNN-BiLSTM模型相比, CNN-BiLSTM-Attention模型的 E_{RMSE} 分别降低10.2%、7.7%和5.9%, E_{MAE} 分别降低了11.2%、19.1%和10.2%, R^2 值分别提升了0.30%、2.44%和6.98%, E_{RPD} 分别提升了11.7%、7.7%和14.9%。Attention机制通过为关键特征分配更高权重, 增强了模型对长期趋势的预测能力, 进一步提升了预测精度与模型稳定性。

由以上数据看出, CNN-BiLSTM-Attention 的预测误差下降更显著, 极大地提升了预测精度与稳定性, 尤其在 6 h 及 12 h 的中长期预测任务中,

其误差和拟合度的改善幅度远超传统模型与其他融合模型, 验证了该模型在较长时序预测场景下的优越性能。

表2 无干扰条件下消融实验结果
Tab.2 results ablation experiment under indifference-free condition

模型	$E_{RMSE}/(10^4 \cdot ns)$			$E_{MAE}/(10^4 \cdot ns)$			R^2			E_{RPD}		
	1 h	6 h	12 h	1 h	6 h	12 h	1 h	6 h	12 h	1 h	6 h	12 h
LSTM	2.843	17.364	22.585	2.260	11.716	17.645	0.983	0.622	0.366	7.738	1.626	1.256
CNN-LSTM	2.618	13.116	17.252	1.985	8.132	9.411	0.986	0.778	0.656	8.379	2.123	1.983
CNN-BiLSTM	2.426	10.402	11.383	1.884	6.056	7.237	0.987	0.861	0.802	9.149	2.704	2.311
本文模型	2.179	9.606	10.712	1.672	4.901	6.498	0.990	0.882	0.858	10.217	2.913	2.655

在有干扰环境下, 开展消融实验。对比 LSTM 模型、CNN-LSTM 模型、CNN-BiLSTM 模型与本文模型的评价指标, 结果见表 3。由表 3 可知, 在 1 h、6 h 和 12 h 的时间序列预测中, 相较于 LSTM 模型, CNN-LSTM 模型的 E_{RMSE} 分别降低 8.9%、20.2%、31.5%, 这说明 CNN 对复杂环境干扰有抑制作用。与 CNN-LSTM 模型相比, CNN-BiLSTM 模型的 E_{RMSE} 分别降低 9.1%、13.0%、

27.2%, 这说明 BiLSTM 模型对长期趋势的捕获, 有效减少了误差。与 CNN-BiLSTM 模型相比, 本文模型通过 Attention 对时间步特征动态加权, 对 12 h 时间序列预测的 R^2 和 E_{RPD} 分别提升至 0.805 与 2.154, 验证了 Attention 在复杂干扰条件下强化全局特征提取、抑制干扰条件波动的作用, 显著提升了时钟误差预测的稳定性、精确性及长时序抗干扰能力。

表3 有干扰条件下消融实验结果
Tab.3 results of ablation experiment under interfering conditions

模型	$E_{RMSE}/(10^4 \cdot ns)$			$E_{MAE}/(10^4 \cdot ns)$			R^2			E_{RPD}		
	1 h	6 h	12 h	1 h	6 h	12 h	1 h	6 h	12 h	1 h	6 h	12 h
LSTM	13.401	21.612	26.883	7.739	16.081	22.392	0.765	0.467	0.124	2.023	1.371	1.068
CNN-LSTM	10.299	17.252	18.404	5.140	11.182	12.968	0.858	0.656	0.592	2.652	1.706	1.566
CNN-BiLSTM	10.824	16.370	14.725	5.127	9.259	9.435	0.863	0.761	0.739	2.732	1.847	1.966
本文模型	9.376	15.011	13.391	4.209	8.855	8.009	0.882	0.809	0.805	2.912	1.959	2.154

3.2 不同模型对比实验

在有干扰条件下, 分别采用本文模型和文献 [20]~文献[23]中的预测模型进行 12 h 预测, 计算各模型的评价指标, 结果见表 4。

表4 不同模型预测结果对比
Tab.4 comparison of prediction results among different models

模型	$E_{RMSE}/(10^4 \cdot ns)$	$E_{MAE}/(10^4 \cdot ns)$	R^2	E_{RPD}
ARIMA ^[20]	17.247	13.925	0.709	1.443
ELM ^[21]	27.458	23.152	0.598	1.265
SVR ^[22]	16.962	15.708	0.696	1.540
XGBoost ^[23]	19.852	17.152	0.699	1.556
本模型	13.391	8.009	0.805	2.154

由表 4 可知, 本文模型的预测精度和稳定性均明显优于其他方法, 其 E_{RMSE} 为 13.391×10^4 ns, 较 SVR 模型降低约 20.8%; E_{MAE} 为 8.009×10^4 ns, 较 ARIMA 模型减少约 42.5%; R^2 为 0.805, 较 ARIMA 模型提升约 13.5%; E_{RPD} 为 2.154×10^4 ns, 较 XGBoost 模型提升约 38.4%。综上, 在复杂干扰环境下, 相较于其他预测模型, 本文模型不仅能更精

确地拟合时钟误差, 还能保持更强的预测稳定性。

3.3 拟合情况

反映模型对时序特征捕捉能力的散点图, 见图 6~图 9。LSTM 模型的散点分布较分散, 预测值的偏差较为明显, 长时间跨度的复杂信息捕捉能力相对有限, 预测值偏离拟合曲线较远。与 LSTM 模型相比, CNN-LSTM 模型的散点相对集中, 与拟合曲线较为接近, 表明 CNN-LSTM 模型在时间序列特征捕捉上有明显提升, 对于短、中和长时间序列, GPS 时钟误差的预测值分布更接近理想状态。与 CNN-LSTM 相比, 采用双向结构的 CNN-BiLSTM 的散点分布更接近拟合曲线, 12 h 数据的偏差明显减小, 表明双向依赖捕获提升了中长序列的预测能力。CNN-BiLSTM-Attention 模型的散点分布最接近拟合曲线, 偏差最小, 6 h、12 h 跨度预测效果提升尤为显著, 这充分体现了注意力机制动态加权关键时间步的增益作用, 实现了更高的整体预测精度和更小的偏差范围。




图6 干扰条件下LSTM模型预测样本拟合

Fig.6 LSTM model prediction sample fitting diagram under interference conditions




图7 干扰条件下CNN-LSTM模型预测样本拟合

Fig.7 CNN-LSTM model prediction sample fitting diagram under interference conditions




图8 干扰条件下CNN-BiLSTM模型预测样本拟合

Fig.8 CNN-BiLSTM model prediction sample fitting diagram under interference conditions




图9 干扰条件下CNN-BiLSTM-Attention模型预测样本拟合

Fig.9 CNN-BiLSTM-Attention model prediction sample fitting diagram under interference condition

4 结论

(1) 提出一种改进 CNN-BiLSTM-Attention 模型的 GPS 时钟误差多特征时间序列预测方法, 通过单差序列 DMAD 方法与三次样条插值进行预处理, 实现异常值的有效检测与消除。利用改进 CNN-BiLSTM-Attention 预测模型开展研究, 显著提升了 GPS 时钟误差数据的预测性能。

(2) 研究结果表明, 本文模型在预测精度及稳定性多项指标方面均显著优于 LSTM 模型等传统预测模型。在短期、中期和长期时间序列预测及有干扰的情况下, 均展现优异的预测效果, 验证了本模型在复杂时间序列预测任务中的鲁棒性和抗干扰能力。

(3) 本文方法可为研发 GPS 智能抗干扰定位及导航系统提供重要参考, 并助力复杂场景下高精度、实时性 GPS 定位模块的实现。

参考文献(References):

- [1] LORRAINE K J S, RAMARAKULA M. A comprehensive survey on GNSS interferences and the application of neural networks for anti-jamming[J]. IETE Journal of Research, 2023, 69(7): 4286-4305.
- [2] LIU H J, LIU F, KONG Y, et al. Improved SSA-Based GRU neural network for BDS-3 satellite clock bias forecasting[J]. Sensors, 2024, 24(4): 1178.
- [3] BHATT A, MEHTA I, PATIDAR P. Leveraging LSTM for predictive modeling of satellite clock bias[C]//2025 8th International Conference on Data Science and Machine Learning Applications. February 16-17, 2025, Riyadh, Saudi Arabia. IEEE, 2025: 25-30.
- [4] VAN HOUDT G, MOSQUERA C, NÁPOLES G. A review on the long short-term memory model[J]. Artificial Intelligence Review, 2020, 53(8): 5929-5955.
- [5] ZHANG F, NIU Y T, ZHOU Q, et al. Intelligent anti-jamming decision algorithm for wireless communication under limited channel state information conditions[J]. Scientific Reports, 2025, 15: 6271.
- [6] XIE Y C, CHEN L, ZHANG K, et al. Deep neural network based anti-jamming processing in the GNSS array receiver[J]. GPS Solutions, 2025, 29(2): 63.
- [7] LI B Y, QIAO J, LU Z K, et al. Influence of sweep interference on satellite navigation time-domain anti-jamming[J]. Frontiers in Physics, 2023, 10: 1063474.
- [8] WANG Y P, LU Z P, QU Y Y, et al. Improving prediction performance of GPS satellite clock bias based on wavelet neural network[J]. GPS Solutions, 2017, 21(2): 523-534.
- [9] ZHANG G C, HAN S H, YE J, et al. A method for precisely predicting satellite clock bias based on robust fitting of ARMA models[J]. GPS Solutions, 2021, 26(1): 3.
- [10] HE S F, LIU J L, ZHU X W, et al. Research on modeling and predicting of BDS-3 satellite clock bias using the LSTM neural network model[J]. GPS Solutions, 2023, 27(3): 108.
- [11] CAI C L, LIU M Y, LI P C, et al. Enhancing satellite clock bias prediction in BDS with LSTM-attention model[J]. GPS Solutions, 2024, 28(2): 92.
- [12] JIN L H, ZHAO W Z, PAN X, et al. Combining semiparametric and machine learning approaches for short-term prediction of satellite clock bias[J]. Scientific Reports, 2025, 15: 11880.
- [13] SONG L J, LIU J H, WANG L L, et al. A comparative study on different machine learning approaches with periodic items for the forecasting of GPS satellites clock bias[J]. Scientific Reports, 2025, 15: 2709.
- [14] HUANG B H, JI Z X, ZHAI R J, et al. Clock bias prediction algorithm for navigation satellites based on a supervised learning long short-term memory neural network[J]. GPS Solutions, 2021, 25(2): 80.
- [15] 吴春俊, 孙越强, 王先毅, 等. 风云三号 D 星天基 BDS 实时定位性能分析[J]. 武汉大学学报(信息科学版), 2023, 48(2): 248-259.
- [16] WU Chunjun, SUN Yueqiang, WANG Xianyi, et al. Assessment of position performance of BDS for space application based on FY-3D satellite[J]. Geomatics and Information Science of Wuhan University, 2023, 48(2): 248-259.
- [17] ZHONG M, HU M N, HU F, et al. An improved lightweight YOLO algorithm for recognition of GPS interference signals in civil aviation[J]. IET Signal Processing, 2024, 2024(1): 9927636.
- [18] 任建吉, 位慧慧, 邹卓霖, 等. 基于 CNN-BiLSTM-Attention 的超短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(8): 108-116.
- [19] REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention [J]. Power System Protection and Control, 2022, 50(8): 108-116.
- [20] LUO S C, WANG B S, GAO Q Z, et al. Stacking integration algorithm based on CNN-BiLSTM-Attention with XGBoost for short-term electricity load forecasting[J]. Energy Reports, 2024, 12: 2676-2689.
- [21] WANG X Y, YANG J J, HUANG M, et al. GNSS interference and spoofing dataset[J]. Data in Brief, 2024, 54: 110302.
- [22] GE H B, LI B F, WU T H, et al. Prediction models of GNSS satellite clock errors: evaluation and application in PPP[J]. Advances in Space Research, 2021, 68(6): 2470-2487.
- [23] YA S S, ZHAO X W, LIU C, et al. Improved BDS-2/3 satellite ultra-fast clock bias prediction based with the SSA-ELM model [J]. Sensors, 2023, 23(5): 2453.
- [24] SYAM W P, PRIYADARSHI S, ROQUÉ A A G, et al. Fast and reliable forecasting for satellite clock bias correction with transformer deep learning[C]//Proceedings of the 54th Annual Precise Time and Time Interval Systems and Applications Meeting, January 23-26, 2023, Long Beach, California. Institute of Navigation, 2023: 76-96.
- [25] LI D A, MA X L, ZHAO J M, et al. Mitigating GNSS multipath effects using XGBoost integrated classifier based on consistency checks[J]. International Journal of Antennas and Propagation, 2022, 2022: 2742620.