

doi:10.19306/j.cnki.2095-8110.2025.03.012

基于 LSTM-Encoder 的区域对流层延迟预测模型

方卓¹, 彭源芳², 蔡成林², 张雪²

(1. 南京数维测绘有限公司, 南京 211808;
2. 湘潭大学自动化与电子信息学院, 湖南湘潭 411105)

摘要: 天顶对流层延迟(ZTD)的精确建模对于全球卫星导航系统(GNSS)的实时高精度定位增强至关重要。由于不同地区的大气水汽存在短时变化特性,经验对流层延迟模型在不同地区往往有显著的精度差异,无法满足精确的区域ZTD预测需求。深度学习方法擅长从时间序列数据中学习复杂的非线性模式和依赖关系。利用2023年澳大利亚地区178个连续运行参考站(CORS)的ZTD数据作为真实值,使用长短期记忆编码器(LSTM-Encoder)网络对2023年的第三代全球气温气压模型(GPT3)数据进行建模,并与GPT3模型、欧洲中期天气预报中心(ECMWF)第五代大气再分析数据集(ERA5)模型、人工神经网络(ANN)模型、广义回归神经网络(GRNN)模型和LSTM模型的实验结果进行了比较。结果表明,LSTM-Encoder模型平均偏差接近于0,均方根误差和平均绝对误差分别为14.4 mm和12.4 mm,优于GPT3,ERA5,GRNN,ANN和LSTM模型,均方根误差分别提高了62.2%,12.3%,59.9%,61.0%和60.0%。此外,比较了LSTM-Encoder模型与GPT3和ERA5模型的空间和时间特性,并讨论了不同神经网络方法在不同预报时长下的性能。所提出的预测模型未来可以用于实时精密单点定位(PPP)中ZTD的初始值确定,在观测方程中引入预测的ZTD作为虚拟观测值,促进ZTD与其他待估参数的分离,从而为高精度GNSS定位服务提供理论支持。

关键词: 深度学习;长短期记忆编码器;对流层延迟;预测模型

中图分类号: P228.4;P352 **文献标志码:** A **文章编号:** 2095-8110(2025)03-0118-12

Regional tropospheric delay prediction model based on long short-term memory encoder

FANG Zhuo¹, PENG Yuanfang², CAI Chenglin², ZHANG Xue²

(1. Nanjing Shuwei Surveying and Mapping Co., Ltd., Nanjing 211808, China;
2. School of Automation and Electronic Information, Xiangtan University, Xiangtan, Hunan 411105, China)

Abstract: Accurate modeling of the zenith tropospheric delay (ZTD) in the troposphere is essential for high-precision real-time positioning in global navigation satellite system (GNSS). Due to the short-term variability characteristics of atmospheric water vapor in different regions, empirical models of tropospheric delay based on meteorological data reanalysis information often show significant differences in accuracy in different regions and cannot meet the demand for accurate regional ZTD predictions. Deep learning methods excel at learning complex nonlinear patterns and dependencies from time series data. In this study, ZTD data from 178 continuously operating refer-

收稿日期: 2024-11-18; **修订日期:** 2025-01-04

基金项目: 国家自然科学基金(42471301)

作者简介: 方卓(1996—),男,助理研究员,主要从事卫星导航定位技术方面的研究。

通信作者: 彭源芳(2000—),女,硕士研究生,主要从事卫星导航定位技术方面的研究。

ence stations (CORS) in Australia in 2023 are used as the true values. The long short-term memory encoder (LSTM-Encoder) network is applied to model data in 2023 from the third-generation global pressure temperature (GPT3) model. The experimental results of the LSTM-Encoder model are compared with those of the GPT3 model, the European Centre for Medium-Range Weather Forecasts (ECMWF) fifth-generation atmospheric reanalysis dataset (ERA5), the artificial neural network (ANN) model, the generalized regression neural network (GRNN) model and the LSTM model. The results show that the LSTM-Encoder model achieves an average bias close to zero, with a root mean square error (RMSE) of 14.4 mm and a mean absolute error of 12.4 mm, outperforming the GPT3, ERA5, ANN, GRNN and LSTM models. The RMSE is improved by 62.2%, 12.3%, 59.9%, 61.0% and 60.0%, respectively. In addition, the spatial and temporal characteristics of the LSTM-Encoder model are compared with those of the GPT3 and ERA5 models, and the performance of different neural network methods at different prediction durations is discussed. The proposed prediction model can be applied to determine the initial values of ZTD in real-time precise point positioning (PPP) in the future. By introducing the predicted ZTD as virtual observations in the observation equations, the separation of the ZTD from other estimable parameters can be facilitated, thus providing theoretical support for high-precision GNSS positioning services.

Key words: Deep learning; Long short-term memory encoder; Tropospheric delay; Prediction model

0 引言

无线电信号在中性大气层中的传播路径要比在真空中长,延长的路径是水蒸气颗粒和干燥气体的相互作用造成的,这种现象被称为对流层延迟^[1]。对流层延迟通常表示为每个地面位置沿天顶方向观测到的数值,即天顶对流层延迟(zenith tropospheric delay, ZTD)^[2]。准确的 ZTD 估计对于提升全球卫星导航系统(global navigation satellite system,GNSS)精密单点定位(precise point positioning,PPP)的收敛速度至关重要^[3-4]。ZTD 主要由天顶静力学延迟(zenith hydrostatic delay,ZHD)和天顶湿延迟(zenith wet delay,ZWD)^[5]两部分组成。其中,ZWD 受多种因素影响,如地区差异、海拔变化和天气波动^[6]。可以通过多种方式获取 ZTD:在 GNSS 数据处理过程中作为未知参数进行估计^[7]、根据实际测量结果建立包含气象参数的模型^[8]、从经验模型发展而来^[9]及通过机器学习技术实现^[10]。

国内外学者在对流层延迟模型方面进行了深入的研究。例如:Hopfield 模型、Saastamoinen 模型和 Black 模型等经典模型^[11-12],还发展了几个系列模型,包括新不伦瑞克大学(University of New Brunswick,UNB)系列、欧洲星基增强系统(European geostationary navigation overlay service,EGNOS)系列、全球气

压气温(global pressure and temperature,GPT)系列和国际 GNSS 服务对流层模型(international GNSS service troposphere models,IGGtrop)系列^[13]。近年来,随着人工智能算法在各个领域的广泛应用,很多学者在对流层延迟建模方面提出了新的模型^[14]。Li 等^[15]提出了基于最小二乘支持矢量机的区域 ZTD 建模方法,结合了 GNSS 观测数据与欧洲中期天气预报中心(European centre for medium-range weather forecasts,ECMWF)的第五代大气再分析产品(the fifth-generation ECMWF reanalysis,ERA5),能够准确捕捉复杂的时空变化特征,显著提升 ZTD 的区域预测精度。Yang 等^[16]提出了结合 GPT3 模型和人工神经网络(artificial neural network,ANN)的区域 ZTD 模型,通过训练区域数据并优化 GPT3 模型的输出,实现了更精确的 ZTD 估计。韦廖军等^[17]提出了融合卷积神经网络和改进注意力机制的 ZTD 组合预测模型,首次将多源数据包括日解算精度、年积日(day of year,DOY)和三维坐标综合应用于 ZTD 预测任务。Zhang 等^[18]使用盲源分离技术提取数据中的潜在特征,并利用反向传播(back-propagation,BP)神经网络建立年均值模型,引入 LSTM 实现南极洲西部的 ZTD 预报。常用的经验模型主要由各分析中心提供的气象再分析资料构建,使用户能够在没有测量气象参数的情况下估计

ZTD^[19]。然而,不足之处在于难以准确模拟快速波动期间的 ZTD^[20]。此外,经验模型在不同地理区域的误差幅度存在显著差异,无法满足在某些特定区域获取高精度的对流层延迟^[21]。作为 GNSS 定位服务中的重要技术,PPP 的主要缺点是收敛时间相对较长^[22]。Tao 等^[23]研究表明,在 PPP 开始时,ZTD 参数与其他估计值(如垂直台站位置和接收机钟差)高度相关,如果能准确估计 ZTD,可以加快 PPP 收敛过程中的参数分离,从而提高收敛速度和定位精度。

ZTD 预测对于高精度 GNSS 定位服务具有重要意义。尽管当前研究在 IGS 测站的 ZTD 预测方面取得了一定成果,但 IGS 测站在许多地区的空间分布不均,测站的覆盖稀疏性限制了区域内 ZTD 变化的长期精确预测。此外,现有的经验模型(如 GPT3 模型)对气象参数的时空分辨率考虑有限,在高时空动态特性与复杂非线性变化的综合捕捉能力上仍存在一定提升空间。基于此,本文利用 2023 年澳大利亚地区 178 个连续运行参考站(continuous operational reference station,CORS)的 ZTD 数据作为参考真值,提出了一种结合长短期记忆编码器(long short-term memory encoder,LSTM-Encoder)改进 GPT3 模型的预测算法,旨在实现区域高精度 ZTD 的长期预测。

1 方法与数据

1.1 LSTM-Encoder 算法

对流层延迟时间序列数据通常表现出短期波动和长期趋势变化的特性。ANN 擅长捕捉时间序列中的非线性关系,但其性能依赖于大规模数据和有效的模型调优,对于剧烈波动的时间序列,ANN 可能会过拟合,从而降低泛化能力^[24]。广义回归神

经网络(general regression neural network,GRNN)基于核回归,每次预测都依赖于输入与训练集中样本之间的相似性^[25]。然而,GRNN 缺乏递归机制或内部状态记忆以前的输入数据,从而无法形成输入序列之间的依赖关系。当 LSTM 处理时间序列数据时,所有信息都必须通过隐藏状态单元逐步传递。虽然 LSTM 机制有助于保留长序列中的一些信息,但早期输入数据可能会被部分遗忘,导致 LSTM 在捕捉长时间序列中的长距离依赖关系时效率往往有所下降^[26]。Encoder 通过生成整个序列的编码表示以捕捉全局时间依赖关系,由于增加了自注意力机制,可以通过自注意力权重在任何时间直接注意输入信息,从而能够更灵活、全面地理解长期依赖关系。本文研究将 LSTM 与 Encoder 相结合,捕捉序列中的全局和局部信息,从而更全面地理解时间序列数据的短期波动和长期趋势。

本文提出了一种混合 LSTM-Encoder 算法,如图 1 所示。考虑到测站的地理位置和时间对 ZTD 具有显著影响,并且 GPT3 模型计算的 ZTD 值易于获得,将测站三维坐标、时间信息及 GPT3 模型计算的 ZTD 值作为输入,输出为 GPT3 ZTD 与 ZTD 参考真值之间的差值。基于 LSTM-Encoder 的预测流程可以表示为

$$D_{i+T+1:t+T+l}^p = F(N_{i,t+T}, L_{i,t+T}, B_{i,t+T}, H_{i,t+T}, Z_{i,t+T}^G) \quad (1)$$

式中: $D_{i+T+1:t+T+l}^p$ 表示 ZTD 残差的预测值; t 表示当前时刻; T 表示时间窗口长度; l 表示预测的时间序列长度; F 表示基于 LSTM-Encoder 的深度学习算法; N 表示年积日; L, B, H 分别表示经度、纬度和高程; $Z_{i,t+T}^G$ 表示 GPT3 模型算出的 ZTD 值。

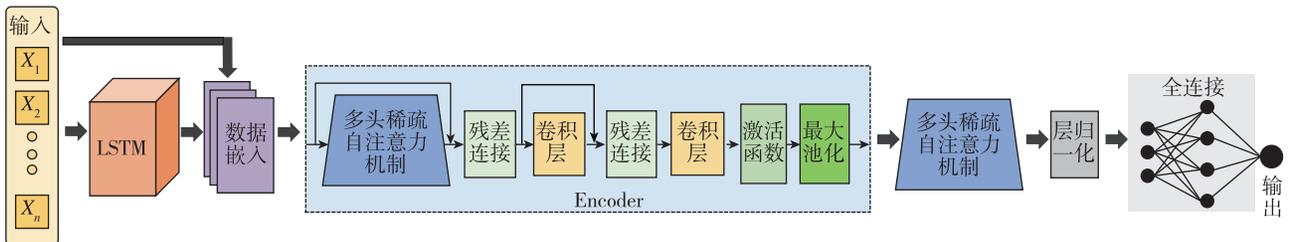


图 1 LSTM-Encoder 算法结构

Fig. 1 The architecture of LSTM-Encoder framework

LSTM 通过输入门、遗忘门、输出门和细胞状态选择性记忆和遗忘信息,捕捉对流层延迟时间序列数据中的长期依赖关系^[27]。作为循环神经网络

的一种改进方法,LSTM 能够有效缓解梯度消失等问题^[28]。针对对流层延迟时间序列的预测任务,本文首先使用 LSTM 网络对站点位置信息和 Z^G 进

行建模,整合站点位置特征和 ZTD 时间序列的动态变化,数据特征经 LSTM 层输出后如式(2)所示。

$$C_{i,t+T} = f_L(L_{i,t+T}, B_{i,t+T}, H_{i,t+T}, Z_{i,t+T}^G) \quad (2)$$

式中: $C_{i,t+T}$ 表示经过 LSTM 层的输出; f_L 表示 LSTM 的更新公式,在此不详细展开。

随后是 Encoder 模块^[29],由数据嵌入层、多头稀疏自注意力机制^[30]、残差连接和卷积层等组成。数据嵌入操作将时间信息与 LSTM 层捕捉到的对流层延迟时间序列的上下文特征进行值编码、位置编码和时间编码,得到 $L_{emb,t,t+T}$,从而产生更丰富的特征表示。同时,利用 Dropout,通过在每次训练迭代中随机停用一定比例的神经元,有助于防止过拟合,如式(3)所示。

$$\text{Dropout}(L_{emb,t,t+T}) \in R^{T \times d_{\text{model}}} \quad (3)$$

采用多头稀疏自注意力机制进行关键特征提取,通过 3 个线性转换将输入矢量映射到查询(Q)、键(K)以及值(V) 3 个输出矩阵上。此处的多头稀疏自注意力机制的稀疏矩阵只包含稀疏性测量 $M(q;k)$ 下的前 u 个 Q,减少了每个注意力层的内存使用量。在多头视角下,这种注意力会为每个头生成不同的 Q-K 对,从而避免了严重的信息丢失。稀疏自注意力机制的输出矩阵如下

$$\text{Attention}(\mathbf{Q}, \mathbf{K}) = \text{Softmax}\left(\frac{\overline{\mathbf{Q}}\mathbf{K}^T}{\sqrt{d_{\text{model}}}}\right) \quad (4)$$

式中: $\overline{\mathbf{Q}}$ 表示稀疏矩阵; d_{model} 表示特征维度,通过 Softmax 函数映射到 $[0, 1]$ 。

经过多头稀疏自注意力机制之后,Encoder 的特征中存在 V 的冗余组合。使用卷积层进行蒸馏操作,优先选择具有优势特征的组合,并在下一层制作一个集中的自注意力特征图。通过蒸馏操作后的输出如下

$$X_{j+1}^i = \text{Maxpool}(\text{Activation}(\text{Conv1d}([X_j^i]_{AB}))) \quad (5)$$

式中: $[X_j^i]_{AB}$ 表示第 j 个注意力机制模块; Conv1d 表示一维卷积层; Activation 表示激活函数; Maxpool 表示最大池化操作。

本文研究使用 2 层 Encoder 堆叠以提高鲁棒性。在遍历所有 Encoder 层后,通过最后一个注意力层对全局特征进行进一步处理,并进行层归一化操作。通过线性回归层对提取的所有特征进行预测,生成对流层延迟残差的最终预测值。

$$D_{t+T+1,t+T+l}^p = FC(X_{j+1}^i) \quad (6)$$

式中, FC 由 2 个全连接层组成。

使用结合了均方误差和正则化项(L1 和 L2)的损失函数,用于训练神经网络,如下

$$L_f = \frac{1}{n} \left(\sum_{i=1}^n (X - \hat{X})^2 + \lambda_1 \sum_{i=1}^n |W_i| + \lambda_2 \sum_{i=1}^n \sqrt{W_i^2} \right) \quad (7)$$

式中: L_f 表示损失函数; n 表示样本个数; X 表示预测值; \hat{X} 表示真实值; λ_1 表示 L1 正则化权重; λ_2 表示 L2 正则化权重; W_i 表示模型的超参数。

1.2 数据收集

ERA5 数据由 ECMWF 于 2019 年 1 月更新,是第五代全球气象再分析数据,详细信息可访问 <https://cds.climate.copernicus.eu> 获取,可提供空间分辨率为 0.25° 、时间分辨率为 1 h 的单级气象网格数据。内华达大地测量实验室(Nevada geodetic laboratory, NGL)的对流层产品,详细信息可查询 <http://geodesy.unr.edu/>,使用喷气推进实验室的 GipsyX1.0 软件每 5 min 生成一次,这些数据的官方标称精度为 4 mm^[31],可作为 ZTD 的参考真值。选择澳大利亚($10^\circ\text{S} \sim 40^\circ\text{S}$, $115^\circ\text{E} \sim 155^\circ\text{E}$) 178 个 CORS 的 ZTD 产品作为参考真值,具体位置如图 2 所示,其中橙色圆点和蓝色圆点分别为训练数据和测试数据。详细位置信息可查阅官方文件(http://geodesy.unr.edu/NGL-StationPages/llh.out_sorted_by_add_date)。

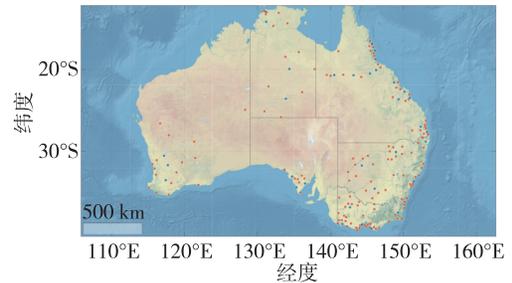


图 2 澳大利亚地区 CORS 分布

Fig. 2 CORS distribution in the Australian region

1.3 数据预处理

从 NGL 中提取了每小时的 ZTD 值,即 N_z ,以便与 ERA5 数据的时间分辨率保持一致。此外,还估算了 GPT3 模型的 ZTD 值,将历时和位置信息输入 GPT3 模型即可轻松获得。这种方法无需补充气象数据,为后续的模式构建提供了基础。

1.4 模型构建

本文研究建立了一个混合模型用于描述时间、

测站位置、GPT3 ZTD 和 ZTD 参考真值之间的关系,如图 3 所示。输入参数为时间、经度、纬度、高程和 GPT3 模型计算的 ZTD。当温度、湿度和大气压力等气象因素发生剧烈波动时,会导致 ZTD 数据出现显著波动。这些波动在神经网络训练过程中可能表现为异常的数值偏离,或引入额外的误差,使模型捕捉真实趋势面临越来越大的挑战。此外,气象因素与参考 ZTD 值之间的关系是高度非线性和复杂的,简单的神经网络结构难以准确模拟,尤其是在高质量训练数据不足的情况下。通过重点预测 GPT3 模型计算的 ZTD 和参考真值之间的差值,可以减轻剧烈数据波动造成的影响。这种方法使神经网络更容易学习相关特征,从而作出更准确的预测。因此,模型的输出为 GPT3 ZTD 与 ZTD 参考真值之差,如式(8)所示,使用 LSTM-Encoder 网络进行训练,最终的 ZTD 预测如式(9)所示。

$$D_z = G_z - N_z \quad (8)$$

$$Z = G_z - D_z \quad (9)$$

式中: G_z 表示 GPT3 模型计算出的 ZTD 值; N_z 表示 NGL 中心提供的 ZTD 值; Z 表示最终预测结果。

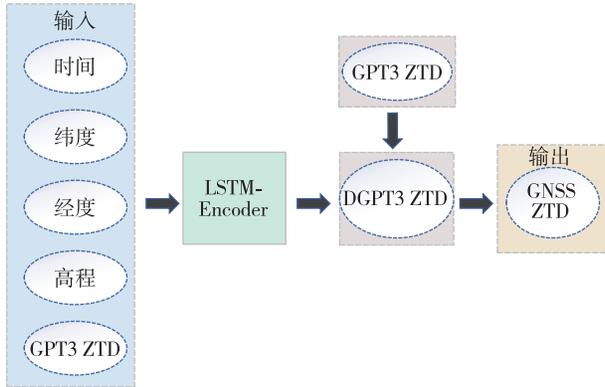


图 3 混合模型预测框图

Fig. 3 Hybrid model prediction structure

2 实验和验证

2.1 实验方案和评价指标

利用图 2 中标注的橙色站点建立区域 ZTD 模型,而蓝色站点则用于预测。观测数据从 2023 年 1 月 1 日~12 月 31 日,时间分辨率为 1 h。在澳大利亚地区随机选择了 33 个站点进行 2023 年的 ZTD 预测。将每个进行 ZTD 预测的站点称为测试站,对于每个测试站,使用距离最近的 9 个站点的数据作为训练数据。在预测过程中,输入是测试站的

GPT3 ZTD,输出是测试站的预测结果。在训练过程中,每个训练周期都会留出 10% 的训练样本作为验证集,在所有周期中验证损失最小的模型被视为最佳模型,并将其用于预测,确保观察到的验证性能达到最佳效果。

在模型训练过程中,优化器选择自适应矩估计,损失函数由均方误差与 L1, L2 正则化项组成。训练采用批量大小为 512 的数据,使用自相关函数分析 ZTD 数据,发现时间窗口长度设置为 64 能够有效反映 ZTD 时间序列中的相关性。输入特征数为 5,输出特征数为 1。针对模型的超参数选择,本文采用网格搜索结合 K 折交叉验证的方法,选取最佳超参数组合。网格搜索的范围涵盖了关键超参数(如学习率、隐藏层单元数、卷积核和丢弃率等),通过交叉验证评估模型在验证集上的表现,从而确保超参数设置的科学性和鲁棒性。表 1 汇总了 LSTM-Encoder 模型的设计参数,以便更清晰地展示具体配置。

表 1 LSTM-Encoder 模型的设计参数

Tab. 1 Design parameters of the LSTM-Encoder model

参数	选择
优化器	自适应矩估计
损失函数	均方误差与 L1, L2 范数正则化
批次	512
学习率	0.001
时间步	64
输入特征数量	5
输出特征数量	1
LSTM 隐藏层单元	300
Encoder 全连接层维度	256
Conv1D 核	3
头数	8
丢弃率	0.08

以 N_z 为基准,为了评估 LSTM-Encoder 模型的有效性,将其估计的 ZTD 值与其他模型估计的 ZTD 值进行了比较,包括 GPT3, ERA5, ANN, LSTM 和 GRNN 模型。实验的整体流程如图 4 所示。使用 3 个统计指标评估不同模型的性能:平均偏差、均方根误差及平均绝对误差,分别如式(10)

~式(12)所示。

$$E_{\text{bias}} = \frac{1}{n} \sum_{i=1}^n (Z_i - Z_i^T) \quad (10)$$

$$E_{\text{rmse}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - Z_i^T)^2} \quad (11)$$

$$E_{\text{mae}} = \frac{1}{n} \sum_{i=1}^n |Z_i - Z_i^T| \quad (12)$$

式中： E_{bias} 表示平均偏差； E_{rmse} 表示均方根误差； E_{mae} 表示平均绝对偏差； Z_i 和 Z_i^T 分别是用不同方法计算得出的 ZTD 值和真实值； n 是样本数。

2.2 GPT3 和 ERA5 模型的精度

以 N_z 为参考真值,统计了澳大利亚 33 个测试站点 2 个广泛使用的模型(GPT3 和 ERA5)在 2023 年期间的 ZTD 误差。图 5 所示为 GPT3 和 ERA5 模型的平均偏差、均方根误差及平均绝对误差分布。表 2 详细列出了这 2 个模型的统计精度。

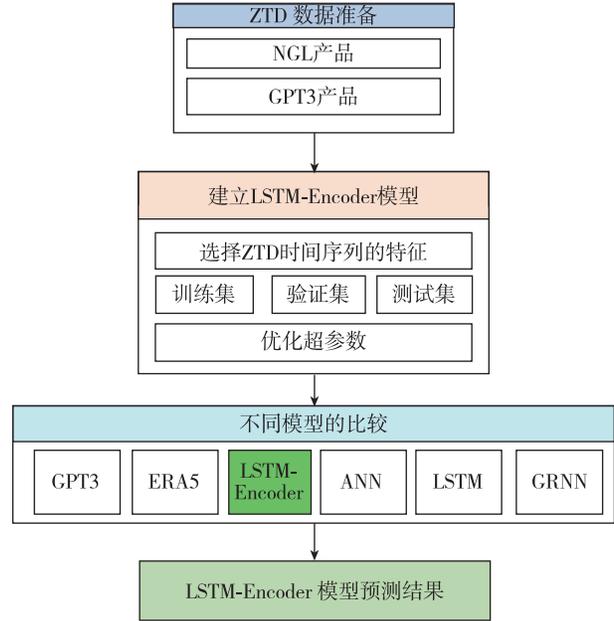


图 4 实验整体流程

Fig. 4 Overall flow of the experiment

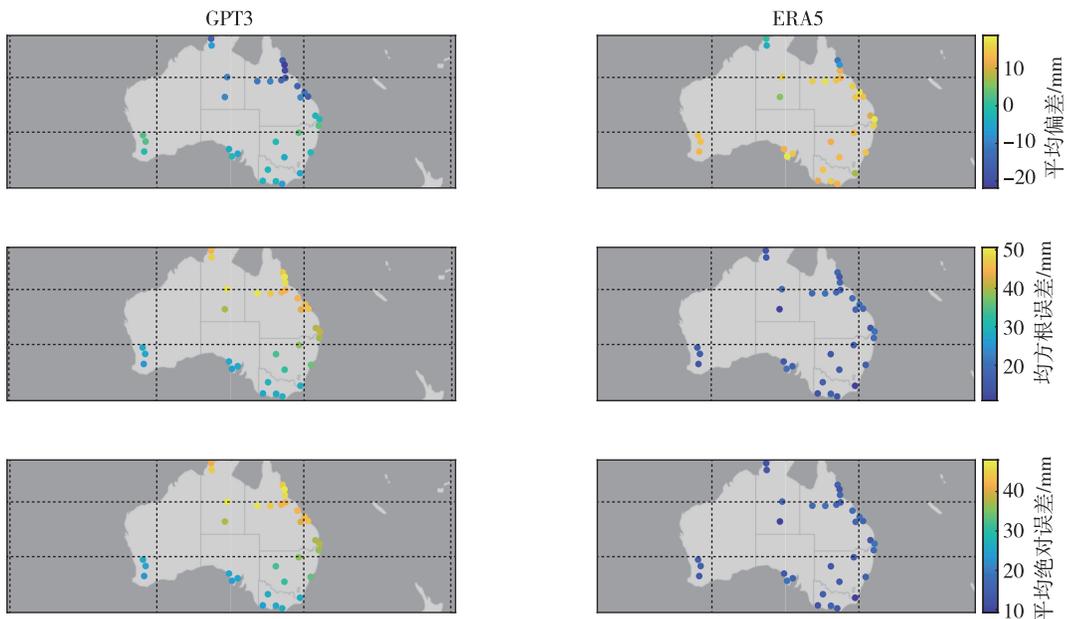


图 5 澳大利亚区域 GPT3 和 ERA5 模型误差评估

Fig. 5 Assessment of GPT3 and ERA5 models error in the Australian region

由图 5 可知,GPT3 模型在澳大利亚区域表现出明显的负偏差,且在东北部偏差较大,南部偏差较小。均方根误差同样在东北部偏大,而在其他地区保持在 40 mm 以下。平均绝对误差分布也反映了这一规律,与均方根误差保持一致性。ERA5 模型的偏差除北部个别站点外,均为正值,且均方根误差分布相对均匀,低于 20 mm。同样,平均绝对误差也显示在 10~20 mm 之间。

表 2 显示,从平均偏差来看,GPT3 模型的计算值偏小,而 ERA5 模型的计算值偏大。GPT3 的均方根误差为 38.2 mm,ERA5 的均方根误差为 16.5 mm,GPT3 的均方根误差远高于 ERA5,说明 GPT3 模型的计算精度比 ERA5 低很多。在平均绝对误差方面,GPT3 模型的平均绝对误差显著高于 ERA5 模型,表明 GPT3 模型的误差在澳大利亚区域明显大于 ERA5 模型。

表 2 GPT3 和 ERA5 模型的误差对比

Tab. 2 Error comparison between GPT3 and ERA5 models

误差指标		mm	
		模型	
		GPT3	ERA5
平均偏差	最大值	3.4	18.7
	最小值	-21.8	-11.3
	平均值	-7.3	11.4
均方根误差	最大值	50.6	20.9
	最小值	25.2	10.8
	平均值	38.2	16.5
平均绝对偏差	最大值	48.0	19.2
	最小值	23.0	9.3
	平均值	35.7	14.7

对 GPT3 和 ERA5 模型的误差分析凸显了来自不同数据源的 ZTD 估计值存在的系统误差问题。需要对这种系统误差进行校准,以有效优化数据利用。因此,本文基于 GPT3 ZTD 数据,采用 LSTM-Encoder 算法建立了一个区域 ZTD 模型。这种方法有望减少 GPT3 模型中普遍存在的系统误差,从而提高 ZTD 预测的准确性。

2.3 不同机器学习模型的精度

由于篇幅所限,图 6 和图 7 仅显示了使用不同模型(即 GPT3, ERA5, ANN, GRNN, LSTM 和 LSTM-Encoder 模型)在 4 个站点(即 WAGN 站、WMGA 站、INGH 站和 GFTH 站)2023 年的 ZTD 预测时间序列的比较,其中 GNSS 为 NGL 的 ZTD 参考真值。

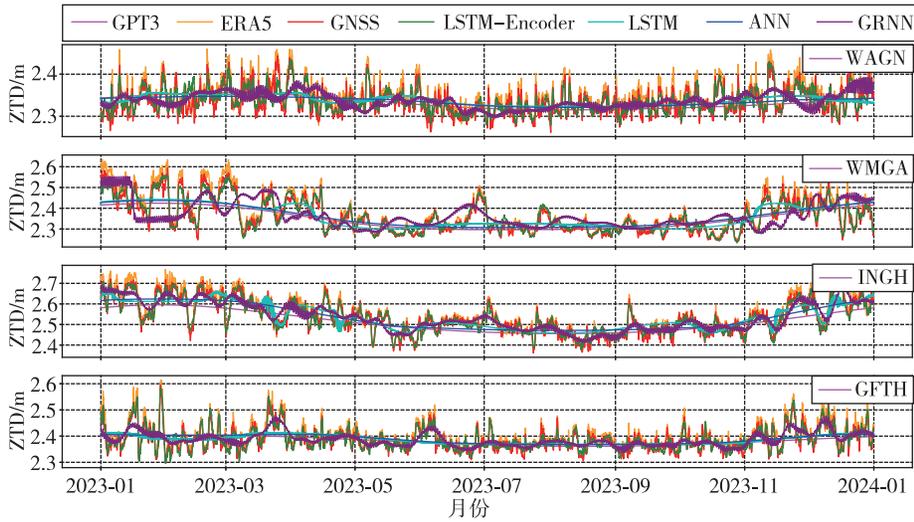


图 6 不同模型的 ZTD 预测结果对比

Fig. 6 Comparison of ZTD prediction results of different models

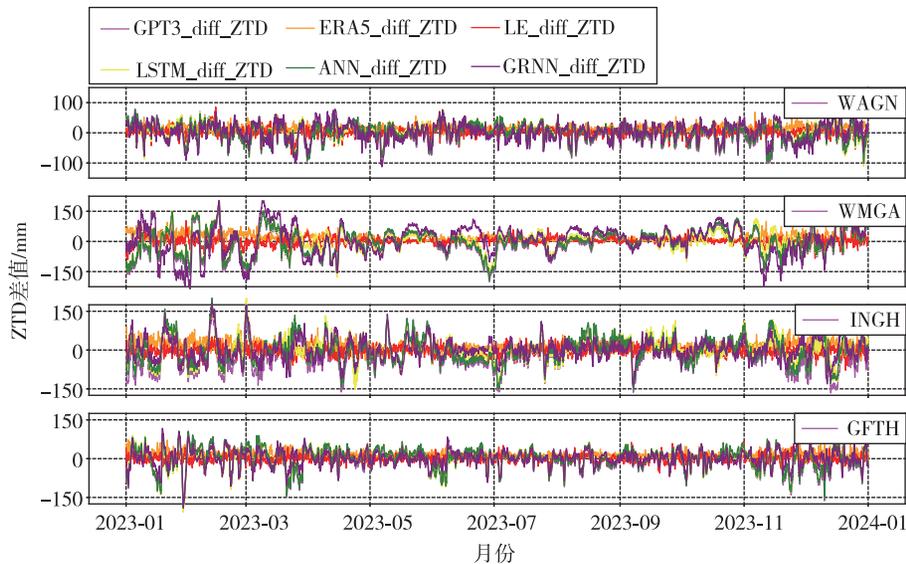


图 7 不同模型的预测 ZTD 偏差对比

Fig. 7 Comparison of predicted ZTD deviation of different models

从图 6 可以看出,GPT3 模型仅能反映 ZTD 的总体趋势,但未能捕捉到其详细变化。同样,LSTM 和 ANN 模型也显示出与 GPT3 模型类似的趋势,表明简单的网络架构可能很难预测复杂数据的变化。与 GPT3,ANN 和 LSTM 模型相比,GRNN 模型在预测的 ZTD 数据中显示出更大的波动,但仍难以准确预测 ZTD 数据的频繁变化。ERA5 模型由于采用了更精细的空间分辨率参数网格,能反映出 ZTD 数据的剧烈波动,但往往会高估 ZTD 值。而 LSTM-Encoder 模型更为准确地反映了 ZTD 数据的剧烈波动,并有效预测了这些变化的峰值。从图 7 可以看出,GPT3,ERA5,LSTM,GRNN,ANN 和 LSTM-Encoder 模型与参考真值的偏差曲线一般在 $-150\sim 150$ mm 之间。其中,LSTM-Encoder 模型的偏差曲线最接近零且波动最小,表明其在预测 ZTD 方面具有最高的准确性和稳定性。

表 3 详细比较了各神经网络模型在测试站预测 ZTD 的统计精度,指标包括平均偏差、均方根误差和平均绝对误差。可以看出,所有模型的平均偏差都接近于零,其中 GRNN 为 0.6 mm,LSTM 为 -0.1 mm,ANN 为 0.1 mm,LSTM-Encoder 为 -0.2 mm。LSTM 和 ANN 模型的最大和最小平均偏差值较大,表明它们在进行对流层延迟数据建模时可能存在较大的系统性误差。GRNN 模型其次,而 LSTM-Encoder 模型在所有站点的偏差波动最小。在均方根误差方面,GRNN,LSTM 和 ANN 模型的平均均方根误差值均约为 36 mm,但 GRNN 模型在个别站点会出现更大的误差,表明其稳定性不如其他模型。LSTM-Encoder 模型在所有站点的平均均方根误

表 3 不同神经网络模型的预测误差对比

Tab. 3 Comparison of prediction errors of different neural network models mm

误差指标	模型				
	GRNN	LSTM	ANN	LSTM-Encoder	
平均偏差	最大值	7.6	14.8	15.3	4.9
	最小值	-5.4	-16.1	-10.9	-6.3
	平均值	0.6	-0.1	0.1	-0.2
均方根误差	最大值	60.6	48.1	48.9	18.8
	最小值	25.7	24.8	24.9	9.9
	平均值	36.0	36.1	37.0	14.4
平均绝对偏差	最大值	58.4	45.5	46.8	16.4
	最小值	23.2	22.7	22.7	8.3
	平均值	33.4	33.4	34.4	12.4

差值最小,低于其他 3 个模型 20 mm,表明其预测准确性更高。就平均绝对误差而言,与均方根误差类似,LSTM-Encoder 模型的误差始终最小,这进一步验证了其性能显著优于其他模型。总而言之,LSTM-Encoder 模型在该区域的预测性能最佳,与 GRNN,ANN 和 LSTM 模型相比,均方根误差分别提高了 59.9%,61.0%和 60.0%。

为了突出所提出模型的优势,以 KNCB 站为例,比较了所提出的模型和其他神经网络模型的 ZTD 差值的概率分布函数,如图 8 所示,横轴表示不同模型的 ZTD 与真实值的差值,纵轴表示不同模型的误差所占百分比。可以看出,LSTM-Encoder,GRNN,ANN 和 LSTM 模型的最大 ZTD 差值分别为 40 mm,120 mm,140 mm 和 138 mm。其中,LSTM-Encoder 模型的 ZTD 差值小于 20 mm 的百分比为 92.3%,而 GRNN,ANN 和 LSTM 模型分别为 47.3%,37.3%和 37.0%。当差值范围设置为小于 40 mm 时,LSTM-Encoder,GRNN,ANN 和 LSTM 模型的百分比分别增至 99.6%,77.9%,67.6%和 68.8%。结果表明,在对流层延迟长期预测任务中,LSTM-Encoder 模型与其他神经网络模型相比,预测误差更低且集中,具有显著优势。

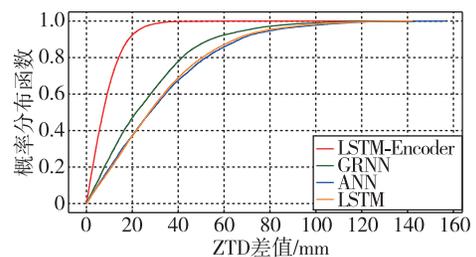


图 8 不同机器学习模型预测结果的概率分布函数

Fig. 8 Probability distribution function of the results of different machine learning models

2.4 LSTM-Encoder 模型预测 ZTD 的空间特性

为了显示 LSTM-Encoder 模型在预测 ZTD 方面空间上的优势,图 9 所示为 LSTM-Encoder,GPT3 和 ERA5 模型在各测试站的误差分布。

从 3 个模型的 ZTD 误差空间分布可以看出,GPT3 模型的误差分布最不均匀,低纬度地区的均方根误差值大于中纬度地区,这可能是由于低纬度地区受赤道低气压带影响,气温较高,降水较丰富。而 ERA5 模型虽然高估了 ZTD 值,但受纬度的影响较小,均方根误差分布较为均匀,在整个区域保持了较低的均方根误差。基于 GPT3 数据,经过 LSTM-

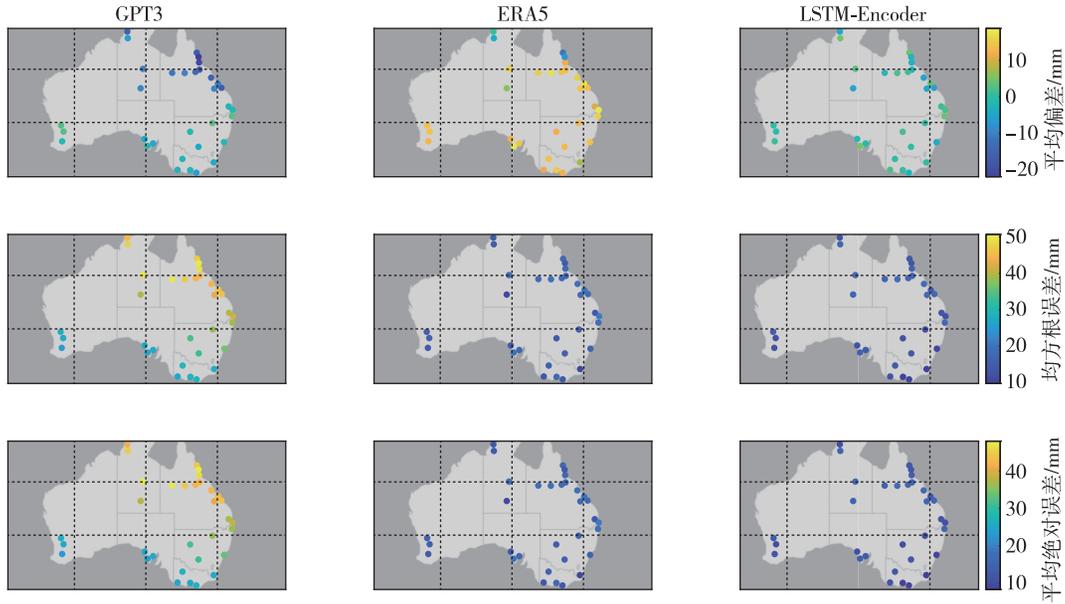


图 9 LSTM Encoder, GPT3 和 ERA5 模型的误差分布

Fig. 9 Error distribution of LSTM Encoder, GPT3 and ERA5 models

Encoder 模型预测后,该区域所有站点的平均偏差、均方根误差及平均绝对误差都有一定程度上的降低,并且误差精度优于 ERA5 模型。

2.5 LSTM-Encoder 模型预测 ZTD 的时间特性

为分析 LSTM-Encoder 模型的时间特性,以 BOOL 测站为例,绘制了 LSTM-Encoder, ERA5 和 GPT3 模型在 2023 年的 ZTD 散点图,如图 10 所示。

从图 10 可以看出,在 2023 年期间,GPT3 模型的平均偏差和均方根误差在大部分时间内接近零,但仍存在一定的短期波动。特别是在 12 月、1 月和 2 月,误差显著增大。这主要是在澳大利亚夏季期

间,空气中的水汽积聚量较高,气旋活动更加不规则,导致 ZTD 受到不规则干扰和气象参数剧烈波动的影响,从而引起平均偏差和均方根误差的升高。此外,4 月和 6 月的误差也较大,可能是与这 2 个月份降雨量的增加有关,降雨引起的水汽剧烈波动会进一步影响 ZTD,导致误差增大。与 GPT3 模型相比,ERA5 模型的平均偏差和均方根误差较小且更为稳定。在 GPT3 数据的基础上引入 LSTM-Encoder 模型后,平均偏差和均方根误差得到了显著降低,同时展现出更高的时间稳定性。

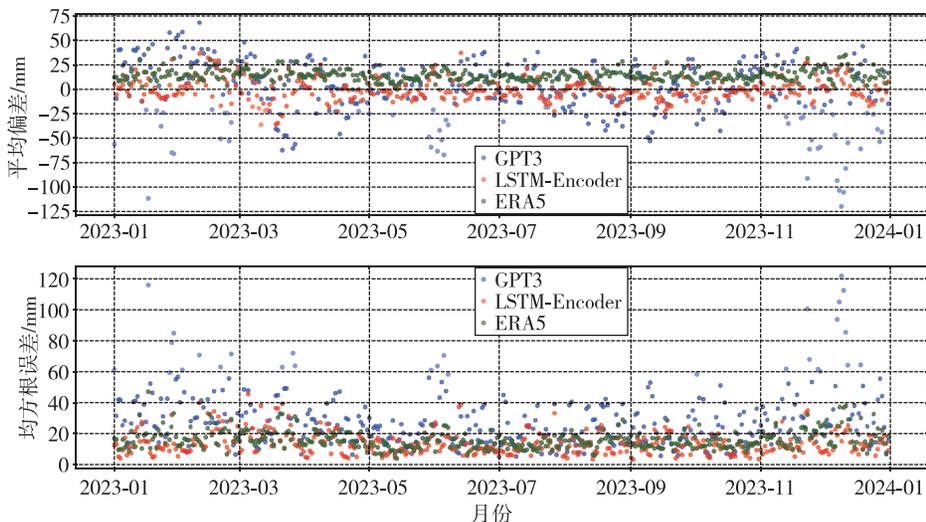


图 10 BOOL 测站 3 种模型的预测散点图

Fig. 10 Scatter plot of the predictions of the three models for BOOL station

2.6 LSTM-Encoder 模型预测 ZTD 在不同时长的性能

本文研究的 ZTD 数据预测时长为 1 h, 为了进一步验证 LSTM-Encoder 模型在不同预测时长的表现, 以均方根误差为评价指标, 验证了所有测试站点在预测时长分别为 6 h 和 24 h 的性能。表 4 所示为不同方法在不同预测时长下的精度差异。结果表明, 在不同的预测时长下, LSTM, ANN 和 GRNN 模型的预测误差均较大, 且 3 种模型没有明显差异。这说明相对简单的神经网络架构难以准确捕获数据中长期波动的复杂模式和依赖性, 其能力不足可能导致预测误差趋于一致。值得注意的是, 相较于 LSTM 和 ANN, GRNN 在个别站点的预测误差更高, 表明其性能可能对输入数据的质量更为敏感, 因此在稳定性方面存在不足。当预测时长从 1 h 增加到 6 h 时, 各个模型的误差无显著变化, 其中 LSTM-Encoder 的误差约为其他模型的一半。而当预测时长从 6 h 增加到 24 h 时, 长时预测中的不确定性会逐渐放大, 各个模型的预测精度均出现下降。然而, 即使在长时预测中, LSTM-Encoder 模型依然表现出显著的优越性, 其均方根误差明显低于其他模型。总之, 无论是在短时预测还是长时预测的场景下, LSTM-Encoder 模型都表现出卓越的预测能力, 能够显著控制误差并提升预测精度, 其性能优于传统的 LSTM, ANN 和 GRNN 模型。

表 4 不同预测时长下的不同神经网络均方根误差

Tab. 4 Mean square error of different neural networks under various prediction durations mm

时长	模型				
	LSTM	ANN	GRNN	LSTM-Encoder	
1 h	最大值	48.1	48.9	60.6	18.8
	最小值	24.8	24.9	25.7	9.8
	平均值	36.1	36.9	36.0	14.4
6 h	最大值	49.3	49.2	60.9	23.1
	最小值	25.5	25.9	26.0	7.9
	平均值	37.5	37.5	36.2	14.0
24 h	最大值	59.3	58.9	73.9	35.9
	最小值	29.0	29.5	29.1	11.2
	平均值	44.3	43.9	43.6	20.1

3 结论

本文提出了一种结合 LSTM-Encoder 的预测

算法, 实现了区域高精度 ZTD 的长期预测, 主要论证过程及结论如下:

1) 为了实现高精度 ZTD 预测, 将测站的经度、纬度、高程以及 GPT3 模型获得的 ZTD 作为关键输入数据来源。模型设计中采用了 LSTM 模块, 以整合站点位置特征与 ZTD 时间序列的动态变化。同时, 引入稀疏自注意力机制, 精准提取关键特征。在特征处理方面, 利用卷积层对输入数据进行特征蒸馏, 通过堆叠 2 层 Encoder 模块, 进一步增强模型的鲁棒性。最终, 通过对流层延迟残差的预测值与 GPT3 模型获得的 ZTD 作差, 获得高精度的 ZTD 预测值。

2) 选取澳大利亚区域 33 个站点对所提出的模型进行验证, 将 LSTM-Encoder 模型与 GPT3, ERA5, GRNN, ANN 和 LSTM 模型的实验结果进行对比。结果表明, LSTM-Encoder 模型的平均偏差接近零, 平均绝对偏差为 12.4 mm, 均方根误差为 14.4 mm。与 GPT3, ERA5, GRNN, ANN 和 LSTM 模型相比, 其性能分别提升了 62.2%, 12.3%, 59.9%, 61.0% 和 60.0%。

3) 为了验证 LSTM-Encoder 模型在不同预测时长下的表现, 还分别进行了 6 h 和 24 h 的对比实验。结果表明, 当预测时长从 1 h 增加到 6 h 时, 各模型的误差变化不大, 其中 LSTM-Encoder 的均方根误差约为其他模型的一半。当预测时长从 6 h 增加到 24 h 时, 由于长时预测中不确定性的逐渐放大, 各模型的预测精度普遍下降, 但是 LSTM-Encoder 的平均均方根误差控制在 20.1 mm, 明显低于其他模型。

本文仅针对 ZTD 实现区域的长期预测, 下一步将对预测算法在实时 PPP 中的应用进行研究。未来的研究还将考虑扩大实验区域, 以实现适用范围更广的 ZTD 预测与应用。

参考文献

- [1] WANG R, MARUT G, HADAŠ T, et al. Improving GNSS meteorology by fusing measurements of several co-located receivers on the observation level [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 7841-7851.
- [2] 郭秋英, 薛学龙, 余森, 等. 基于多模 PPP-AR 技术的大气水汽探测性能分析 [J]. 导航定位与授时, 2023, 10(6): 93-102.
GUO Qiuying, XUE Xuelong, YU Miao, et al. Performance analysis of atmospheric water vapor detection based on multi-constellation PPP-AR technology [J].

- Navigation Positioning and Timing, 2023, 10(6): 93-102(in Chinese).
- [3] LV K, CAI C, CAI Y, et al. A static precise single-point positioning method based on carrier phase zero-baseline self-differencing[J]. Scientific Reports, 2024, 14(1): 12590.
- [4] HUANG L, ZHU G, PENG H, et al. An improved global grid model for calibrating zenith tropospheric delay for GNSS applications[J]. GPS Solutions, 2023, 27(1): 17.
- [5] LI H, WANG X, WU S, et al. An improved model for detecting heavy precipitation using GNSS-derived zenith total delay measurements[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 5392-5405.
- [6] 李黎, 匡翠林, 朱建军, 等. 基于实时精密单点定位技术的暴雨短临预报[J]. 地球物理学报, 2012, 55(4): 1129-1136.
- LI Li, KUANG Cuilin, ZHU Jianjun, et al. Rainstorm nowcasting based on GPS real-time precise point positioning technology[J]. Chinese Journal of Geophysics, 2012, 55(4): 1129-1136 (in Chinese).
- [7] HADAS T, HOBIGER T, HORDYNIÉC P. Considering different recent advancements in GNSS on real-time zenith troposphere estimates[J]. GPS Solutions, 2020, 24(4): 99.
- [8] FENG P, LI F, YAN J, et al. Assessment of the accuracy of the Saastamoinen model and VMF1/VMF3 mapping functions with respect to ray-tracing from radiosonde data in the framework of GNSS meteorology[J]. Remote Sensing, 2020, 12(20): 3337.
- [9] LEANDRO R F, LANGLEY R B, SANTOS M C. UNB3m_pack: a neutral atmosphere delay package for radiometric space techniques[J]. GPS Solutions, 2008, 12(1): 65-70.
- [10] HE L, YAO Y, XU C, et al. A new global ZTD forecast model based on improved LSTM neural network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 9606-9614.
- [11] CHEN B, LIU Z. A comprehensive evaluation and analysis of the performance of multiple tropospheric models in China region[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 54(2): 663-678.
- [12] SAASTAMOINEN J. Contributions to the theory of atmospheric refraction[J]. Bulletin Géodésique (1946-1975), 1972, 105(1): 279-298.
- [13] LI W, YUAN Y, OU J, et al. IGGtrop_SH and IGGtrop_rH: two improved empirical tropospheric delay models based on vertical reduction functions[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(9): 5276-5288.
- [14] SHAMSHIRI R, MOTAGH M, NAHAVANDCHI H, et al. Improving tropospheric corrections on large-scale Sentinel-1 interferograms using a machine learning approach for integration with GNSS-derived zenith total delay (ZTD)[J]. Remote Sensing of Environment, 2020, 239: 111608.
- [15] LI S, XU T, JIANG N, et al. Regional zenith tropospheric delay modeling based on least squares support vector machine using GNSS and ERA5 data[J]. Remote Sensing, 2021, 13(5): 1004.
- [16] YANG F, GUO J, ZHANG C, et al. A regional zenith tropospheric delay (ZTD) model based on GPT3 and ANN[J]. Remote Sensing, 2021, 13(5): 838.
- [17] 韦廖军, 莫儒, 任晓斌, 等. 基于改进注意力机制 CNN-ATT 的区域性 ZTD 预测模型[J]. 导航定位与授时, 2024, 11(3): 85-100.
- WEI Liaojun, MO Nuo, REN Xiaobin, et al. A regional ZTD prediction model based on improved attention mechanism CNN-ATT [J]. Navigation Positioning and Timing, 2024, 11(3): 85-100(in Chinese).
- [18] ZHANG Q, LI F, ZHANG S, et al. Modeling and forecasting the GPS zenith troposphere delay in West Antarctica based on different blind source separation methods and deep learning[J]. Sensors, 2020, 20(8): 2343.
- [19] CHEN P, MA Y, LIU H, et al. A new global tropospheric delay model considering the spatiotemporal variation characteristics of ZTD with altitude coefficient[J]. Earth and Space Science, 2020, 7(4): e2019EA000888.
- [20] BÖHM J, MÖLLER G, SCHINDELEGGER M, et al. Development of an improved empirical model for slant delays in the troposphere (GPT2w)[J]. GPS Solutions, 2015, 19: 433-441.
- [21] YAO Y, PENG W, XU C, et al. Enhancing real-time precise point positioning with zenith troposphere delay products and the determination of corresponding tropospheric stochastic models[J]. Geophysical Supplements to the Monthly Notices of the Royal Astronomical Society, 2016, 208(2): 1217-1230.
- [22] CUI B, LI P, WANG J, et al. Calibrating receiver-type-dependent wide-lane uncalibrated phase delay biases for PPP integer ambiguity resolution[J]. Journal of Geodesy, 2021, 95(7): 82.
- [23] TAO J, CHEN G, ZHANG G, et al. Real-time regional tropospheric wet delay modeling and augmen-

- tation performance for triple-frequency PPP/PPP-IAR during typhoon weather [J]. *GPS Solutions*, 2024, 28(2): 96.
- [24] BISHOP C M. *Neural networks for pattern recognition* [M]. Oxford: Oxford University Press, 1995.
- [25] SPECHT D F. A general regression neural network [J]. *IEEE Transactions on Neural Networks*, 1991, 2(6): 568-576.
- [26] GERS F A, SCHRAUDOLPH N N, SCHMIDHUBER J. Learning precise timing with LSTM recurrent networks[J]. *Journal of Machine Learning Research*, 2002, 3(Aug): 115-143.
- [27] KULSHRESTHA A, CHANG L, STEIN A. Use of LSTM for sinkhole-related anomaly detection and classification of InSAR deformation time series [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 4559-4570.
- [28] PU K, LIU X, LIU L, et al. Water vapor retrieval using commercial microwave links based on the LSTM network [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 4330-4338.
- [29] ZHANG Z, JIANG T, LIU C, et al. An effective classification method for hyperspectral image with very high resolution based on encoder-decoder architecture [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 1509-1519.
- [30] WANG X, SUN S, XIE L, et al. Efficient conformer with prob-sparse attention mechanism for end-to-end speech recognition [J]. *arXiv preprint arXiv: 2106. 09236*, 2021.
- [31] BLEWITT G, HAMMOND W, KREEMER C. Harnessing the GPS data explosion for interdisciplinary science [J]. *Eos*, 2018, 99(2): e2020943118.

(编辑:孟彬)