

HUANG Can, LI Junyu, LIU Lilong, HUANG Liangke, WEI Lüquan. Application of Improved Model Based on LSTM in Ionospheric TEC Forecast (in Chinese). *Chinese Journal of Space Science*, 2025, 45(5): 1256–1264. CSTR:32142.14.cjss.2024-0112. DOI:10.11728/cjss2025.05.2024-0112

基于 LSTM 的改进模型在电离层 TEC 预报中的应用*

黄 灿 黎峻宇 刘立龙
黄良珂 韦律权

(桂林理工大学测绘地理信息学院 桂林 541006)

(广西空间信息与测绘重点实验室 桂林 541006)

摘 要 电离层延迟是全球卫星导航定位中重要的误差源之一, 提高电离层总电子含量 (Total Electron Content, TEC) 预报精度对改善卫星导航定位精度极其重要. 本文联合滑动窗口 (Sliding Window) 和长短时记忆 (Long-Short-Term Memory, LSTM) 神经网络, 以滑动窗口算法对输入序列数据集不断更新并测试不同输入序列长度对应模型的精度, 最后以预测值来更新输入数据序列的最后 10%, 进而构建 TEC 预报模型 SLSTM (Sliding Window on Long-Short-Term Memory). 验证结果表明, 该模型在平静期和磁暴期预测残差绝对值小于 5 TECU 的比例均达 85% 以上, 较传统 LSTM 模型对应值占比增加了 49%, 71%, 均方根误差 (RMSE) 低 31%, 35%; 其预报结果的平均绝对误差 (MAE) 减少 25%, 32%; SLSTM 模型预测结果的 RMSE 均值、MAE 均值均比传统 LSTM 模型、BP 模型小.

关键词 电离层, 总电子含量, 长短时记忆网络, 神经网络, 改进模型

中图分类号 P352

Application of Improved Model Based on LSTM in Ionospheric TEC Forecast

HUANG Can LI Junyu LIU Lilong
HUANG Liangke WEI Lüquan

(College of Geomatics and Geoinformation, Guilin University of Technology, Guilin 541006)

(Guangxi Key Laboratory of Spatial Information and Mapping, Guilin 541006)

Abstract Ionospheric delay is one of the most important sources of error in global satellite naviga-

* 广西科技计划项目 (GuikeAD23026177, 2024 GXNSFDA010041), 国家自然科学基金项目 (42304018, 42064002), 桂林理工大学科研启动基金项目 (GUTQDJJ6616032), 广西空间信息与测绘重点实验室基金项目 (21-238-21-05) 和 2024 年度广西高校中青年教师科研基础能力提升项目 (2024 KYZD03) 共同资助

2024-09-05 收到原稿, 2025-01-08 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

tion and positioning. Improving the prediction accuracy of ionospheric Total Electron Content (TEC) is very important to improve the positioning accuracy of satellite navigation. In this paper, we combine sliding window and Long-Short-Term Memory (LSTM) neural network, and use sliding window algorithm to continuously update the input time series data set. We tested the accuracy of the models corresponding to different input sequence lengths and recorded them, and found that the accuracy of the last 10% of the input data series was the best when the predicted value was updated. Finally, we used the sliding window method to update the last 10% of the input data series with the predicted value to build the TEC prediction model. The newly constructed model, traditional LSTM model and BP model are used to predict the same TEC time series data, and Root Mean Square Error (RMSE), absolute residual error and Mean Absolute Error (MAE) are used to evaluate the accuracy of the model prediction results, and verify the prediction performance of the new model. The experimental results show that the proportion of residual absolute value less than 5 TECU predicted by the newly constructed model SLSTM (Sliding Window on Long-Short-Term Memory) in both the calm period and the magnetic storm period exceeds 85%, and the proportion of predicted residual absolute value less than 5 TECU corresponding to the traditional LSTM model increases by 49% and 71%. On the other hand, compared with the traditional LSTM model, the root-mean-square error of the new model is reduced by 31% and 35%, respectively, and the average absolute error is reduced by 25% and 32%, respectively. In addition, we can also see that the RMSE mean values and MAE mean values of SLSTM model are smaller than those of traditional LSTM model and BP model.

Key words Ionosphere, Total Electron Content (TEC), Long-Short-Term Memory (LSTM) network, Neural network, Improved model

0 引言

电离层是地球大气层的一部分, 电离层电子浓度对于无线电信号的传播、导航系统的性能和卫星轨道的稳定性等有着重要影响^[1]. 电离层总电子含量 (Total Electron Content, TEC) 是衡量电离层电子浓度的一个重要参数, 由于空间天气的变化剧烈, 其变化趋势具有非线性、不平稳性及周期性等特点, 因此对其准确预测对于卫星导航定位具有重要意义^[2,3].

目前, 对 TEC 的预报方法一般有经验统计、数据同化方法及数理统计模型等, 经验模型是根据已有经验模型, 基于现有的大量观测数据建立的, 易于操作, 但预测精度并不理想^[4]. 数据同化方法是将测量数据同化到电离层模型中来有效提高监测和预报系统精度的方法^[5]. 数理统计模型是通过数学方法对 TEC 时间序列进行拟合建立的, 在超短期预报领域具有显著优势^[6]. 由于深度学习对于处理非线性、复杂程度高的序列具有天然优势, 近年来基于深度学习的 TEC 建模逐渐兴起, 并展现出了较好的优势. 文献 [7] 采用长短期记忆方法 (Long-Short-Term Memory, LSTM) 与国际参考电离层 (International Ref-

erence Ionosphere, IRI) 模型构建组合预测模型, 对欧洲平静期的 TEC 进行预测, 发现组合预测模型的预测性能比 IRI 梯度法更为稳定, 消除了单一 LSTM 模型预测结果中的大部分异常值, 提高了模型的预测精度. 文献 [8] 采用 LSTM 模型对全球 TEC 进行预测, 结果表明, 电离层不同活跃期及不同纬度的预报结果有所差别, 模型预测结果的 RMSE 随预测时间和地磁活跃程度的增加而变大, 且模型在中高纬度地区的预测精度优于低纬度地区. 文献 [9] 对比了差分自回归移动平均 (Auto-Regressive Integrated Moving Average, ARIMA) 模型、LSTM 模型和序列到序列 (Sequence-to-Sequence, Seq2Seq) 模型对不同磁暴条件下电离层 TEC 的短期预报效果, 结果表明, LSTM 可以达到最好的预测精度, 并且对于准确的趋势预测具有更好的鲁棒性. 文献 [10] 融合因果卷积和 LSTM 构建深度学习模型, 以太阳活动指数 $F_{10.7}$ 、地磁活动指数 Dst 及 TEC 作为输入, 实现提前 24 h 电离层 TEC 预报, 与单一 LSTM 模型相比, 组合模型 RMSE 降低了 15%, 预报精度更高.

这些研究表明, 神经网络在电离层 TEC 预测中有较好的效果, 尤其 LSTM 神经网络通过独特的设

计避免了长期依赖问题,许多学者根据 LSTM 的这一优点,尝试将其用于 TEC 预报.但对长时间序列的预测仍然可能存在梯度消失和梯度爆炸问题造成预报精度严重降低^[11].为此,本文引入滑动窗口法,根据时间推移,周期性地更新数据集,从而将长时间序列划分为周期性的短时间序列.结合 LSTM 和滑动窗口法解决长时间序列预测时误差较大的问题.

1 模型原理

1.1 长短期记忆网络

LSTM 在隐藏层中新增一个单元细胞状态来记录长期的状态,使 LSTM 可以学习长期依赖信息,解决了在训练过程中发生的梯度消失和爆炸的问题^[12].LSTM 在对非平稳性时间序列进行预报时有着较好的效果^[13].

LSTM 单元结构如图 1 所示,其包含 3 个控制门,分别是遗忘门、输入门和输出门,通过这 3 个门可以实现记忆信息与当前信息的保留和遗弃.在 LSTM 细胞结构中主要有细胞状态 C_t 和隐藏状态 h_t 被传递到每一个细胞. LSTM 的信息流计算过程如下^[14]:

$$f_t = \sigma(W_f X_t + U_f h_{t-1} + b_f), \quad (1)$$

$$i_t = \sigma(W_i X_t + U_i h_{t-1} + b_i), \quad (2)$$

$$\tilde{C}_t = \tanh(W_c X_t + U_c h_{t-1} + b_c), \quad (3)$$

$$C_t = C_{t-1} \odot f_t + i_t \odot \tilde{C}_t, \quad (4)$$

$$o_t = \sigma(W_o X_t + U_o h_{t-1} + b_o), \quad (5)$$

$$h_t = o_t \odot \tanh(C_t). \quad (6)$$




图 1 LSTM 网络结构

Fig. 1 LSTM network structure

其中, X_t , h_t , $\tilde{C}_t$, C_t 分别为 t 时刻 LSTM 单元的输入向量、隐藏状态向量、细胞输入激活向量和细胞状态向量; f_t , i_t , o_t 分别为遗忘门、输入/更新门和输出门的激活向量; W , U , b 为训练时需要学习的权矩阵和偏置向量参数; $\odot$ 表示 Hadamard 积; σ 为 Sigmoid 激活函数; $\tanh$ 为激活函数.

1.2 滑动窗口

常见的神经网络模型预测方法一般有单步预测和多步预测.前者是用多个历史数据 X_n 预测未来 1 个数据,一轮预测完成后,输入数据仍为 X_n ,因此只能预测未来 1 个固定值;后者是用多个历史数据预测未来多个数据,输入数据仍然固定不变,导致预测结果也是固定的^[15].本文引入滑动窗口算法对输入序列数据集不断更新,有效解决了预测值固定不变的问题^[16].此外,当预测时序较长时,输入数据全部替换成预测值导致误差累积,降低整体预测精度.为解决此问题,采用间隔时间将输入部分的预测值换回真值,即把长时序拆分为短时序,达到减少误差累积问题.

1.3 联合滑动窗口和 LSTM 的预报模型

联合滑动窗口的目的是更新参数^[17],以解决模型在长时序预测中预测值固定而导致误差较大的问题.以步长 5 为例,模型预测过程如图 2 所示.

图 2 中数据输入部分的数字表示历史数据,预测值部分的字母 P 代表预测数据,将上一次预测值作为下一次的输入值放到最后,经过 LSTM 模型预测得到新的预测值,有效解决传统 LSTM 固定预测的问题.

本文基于滑动窗口的 LSTM 建立 TEC 预报模型,详细步骤如下.

(1) 数据归一化,以便提高模型训练的稳定性和




图 2 联合滑动窗口的 LSTM 预测流程

Fig. 2 LSTM prediction diagram of joint sliding window

收敛速度, 归一化公式如下:

$$X_{mn} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}. \quad (7)$$

其中, X_{mn} 为归一化后 0~1 的数据, X 为每小时 TEC 值, $X_{\min}$ 为最小 TEC 值, $X_{\max}$ 为最大 TEC 值.

(2) 寻找误差骤增位置. 通过不断实验寻找误差骤增的时间节点, 将其之前的数据划分为一个窗口. 当预测 T 个步长发生误差突然变大时, 将预测值重新替换为真值, 替换前的数据放在一个窗口, 替换后的为新窗口, 从而确定窗口的时间长度. 窗口更新参数的过程可描述为^[18]

$$X_{T_i, \text{act}} = (X_{T_i, -n}, \cdots, X_{T_i, -1}, X_{T_i, 0}), \quad (8)$$

$$X_{T_i, \text{act}} \rightarrow \text{LSTM} \rightarrow X_{T_i, \text{per}_j}, \quad (9)$$

$$T_{i, \text{act+per}_j} = (X_{T_i, -n+k}, \cdots, X_{T_i, 0}, X_{T_i, \text{per}_1}, \cdots, X_{T_i, \text{per}_k}). \quad (10)$$

式中, $X_{T_i, \text{act}}$ 表示周期 i 的真值, X_{T_i, per_j} 表示周期 i 中第 j 个预测结果, 式 (9) 表示第 i 个周期的预测过程.

(3) 预测模型实验采用自适应矩估计 (Adaptive Moment Estimation, Adam), 损失函数为均方误差 (Mean-Square Error, MSE).

2 实验结果与分析

2.1 数据源与研究区

选取 2022 年磁暴期、平静期的 TEC 数据, 采用欧洲定轨中心 (Center of Orbit Determination at Europe, CODE) 提供的 ($95^{\circ}\text{E}-110^{\circ}\text{E}$, $20^{\circ}\text{N}-30^{\circ}\text{N}$) TEC 数据, 其时空分辨率为 $2.5^{\circ} \times 5^{\circ} \times 1 \text{ h}$. 云南省位于 $97^{\circ}31'\text{E}-106^{\circ}11'\text{E}$, $20^{\circ}8'\text{N}-29^{\circ}15'\text{N}$, 北回归线横贯云南省南部. 已有的研究表明, 整体来说, 随着纬度变小, 电离层 TEC 预报精度呈下降趋势, 但存在局部预报误差出现峰值的情况^[6,19,20]. 低纬地区存在喷泉效应形成的电离层赤道异常, 使得低纬度地区的电离层变化相对复杂^[21], TEC 预报难度也随之增加, 而云

南省处在赤道异常区北峰区^[22]. 因此, 以地处中国低纬度地区的云南省作为研究区域.

选用暴时扰动指数 (Disturbance Storm Time Index, Dst 指数) 作为划分磁暴期和平静期的依据, Dst 指数用于表征全球范围的环电流强度^[22], 其能够清晰反映磁暴发生的强度. 表 1 为 Dst 指数对应的地磁活动强度.

2.2 精度评价指标

选取均方根误差 (Root Mean Square Error, RMSE)、残差绝对值 (ε)、平均绝对误差 (Mean Absolute Error, MAE) 进行精度评价, 其公式分别为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - x_i)^2}, \quad (11)$$

$$\varepsilon = |p_i - x_i|, \quad (12)$$

$$E_{\text{MAE}} = \frac{1}{n} \times \sum_{i=1}^n |p_i - x_i|. \quad (13)$$

其中, p_i 为预测值, x_i 为真值. 公式中的指标值越小, 说明预报精度越高, 模型性能越好.

2.3 窗口大小实验结果

为找到合适的更新输入数据的窗口大小, 采用 1.3 节中更新输入数据的方法, 利用 120 h 时长的 TEC 作为输入值 (其中包括部分用预测值代替真值的序列), 未来 1 h 的 TEC 作为输出值训练模型, 基于新模型预测下 1 h 的 TEC. 基于这种策略, 进行了 72 h (分辨率为 1 h) 的 TEC 连续预测实验. 并统计了输入数据中预测值代替真值序列在整个输入数据中的占比 (P) 与误差之间的关系, 以求得预报值误差最小对应的输入数据中的 P (即合适的更新输入数据的窗口大小), 结果如图 3 所示. 从图 3 中可以看出, 在一定范围内, 随着输入数据中更新序列占比的增加, 预测效果越来越好, 当占比等于 10% 时, 误差最小. 但大于 10% 以后, 随着预测值在训练集的占比不断提高, 预测误差反而逐步上升. 这可能是因为 TEC 数据本身具有非线性、不平稳性的特点, 当采用具有一定特征、有效时长的真值作为输入进行预测

表 1 Dst 指数对应地磁活动强度

Table 1 Intensity of geomagnetic activity corresponding to the Dst index

Dst / nT	≤ -100	$(-100, -50]$	$(-50, -30]$	> -30
地磁活动强度	强	中	弱	平静

时,模型可能捕捉不到一些一定特征期之外的TEC变化;当用一定的预测值代替真值作为输入时,模型本身的自相关性可能有助于模型捕捉到真值反应之外的趋势^[23,24],从而提高预测精度.在本实验中,当 P 为10%时预测效果最好,此后,RMSE呈现不断上升趋势,预报精度逐渐降低.因此,根据该方法构建新模型,记为SLSTM (Sliding Window on Long-Short-Term Memory),并进行TEC预报.

根据 Dst 指数对应磁暴强度,筛选2022年 $Dst < -30$ nT时的TEC数据作为磁暴期数据,平静期选取的是 $Dst > -30$ nT且前一天没有发生磁暴的TEC数据.选取的数据对应图4的 Dst 指数,由此共筛选出36段磁暴期TEC时序,总时长为2058 h,32段平静期TEC时序,总时长5654 h.

2.4 模型预报结果

为验证模型精度,分别利用传统LSTM模型和SLSTM模型对1.3节中筛选出来的2022年云南省




图3 P 与误差之间的关系

Fig. 3 Relationship between prediction step size and error

及其周边地区磁暴期和平静期、共20个格网的TEC进行预测.每个格网的平静期和磁暴期分别单独创建数据集和模型,每个数据集最后12 h的数据作为参考值.要说明的是,模型训练时,二者输入的TEC长度一致;两个模型的区别在于,SLSTM模型采用预测值代替部分真值的方法进行构建,而LSTM模型全部使用真值作为输入进行构建.限于篇幅,图6给出在20个格网点处最后一段平静期、磁暴期TEC时序LSTM或SLSTM的TEC预报值与TEC真值的对比结果.其中,横坐标两整数之间为单格网点预报时长(12 h)对应的全部结果,例如0~1的曲线为1号格网点(对应经纬度见图5).图中平静期两个格网点号之间的序列对应的是19:00 UT到次日06:00 UT的结果,磁暴期对应的是03:00—14:00 UT,即平静期和磁暴期最后一段TEC时序的12 h.由图5和图6可知,TEC由西南向东北呈下降趋势,磁暴期波动更大.在平静期,相对于传统LSTM模型,新模型预测值与真值更贴近;在磁暴期,TEC波动较大,传统的LSTM模型较难捕捉TEC短期剧烈跳变,相比LSTM模型,SLSTM则可对TEC的短期双峰和单峰结构有更好的描述,预测值与真值符合更好.此外,从残差大小分布来看,SLSTM的 ε 基本都比LSTM的小,LSTM模型的 ε 起伏较大,SLSTM的对应值相对平稳,说明SLSTM模型预报性能较好.

为具体分析SLSTM模型预报精度的提高程度,分别统计了各模型 $\varepsilon \leq 5$ TECU的占比,结果如图7和图8所示,在平静期,SLSTM模型 $\varepsilon \leq 5$ TECU的占比为90.0%,比传统LSTM模型提升49%,在磁暴期SLSTM模型 $\varepsilon \leq 5$ TECU的占比为86.2%,比传统LSTM模型增加71%.SLSTM的残差主要集中在0 TECU附近;而传统LSTM模型的残差主要集中在5 TECU左右,与参考值有明显系统偏差,也侧




图4 2022年 Dst 指数

Fig. 4 Dst index in 2022

面说明了本文建模的合理性和必要性. 总体来说, 与传统 LSTM 模型相比, SLSTM 模型预报精度更高, 尤其在磁暴期预报精度提高更大.

为进一步量化分析 SLSTM 模型预报精度的提高效果, 统计了不同活跃期各模型预报结果的平均 MAE 和 RMSE, 见表 2 和表 3. 表 2 中 SLSTM 模型在平静期预报结果的平均 MAE 为 2.1 TECU, 磁暴期为 2.3 TECU, LSTM 模型对应 MAE 分别为 2.8 TECU 和 3.4 TECU, SLSTM 模型的平均 MAE 相比传统 LSTM 模型低 25% 和 32%. 在平静期,

SLSTM 模型的 MAE 范围为 1.0~3.4 TECU, LSTM 模型为 1.8~4.6 TECU, 在磁暴期, SLSTM 模型的 MAE 范围为 1.1~3.5 TECU, LSTM 模型为 2.3~5.7 TECU, 表明 SLSTM 模型的预测效果比 LSTM 精度更高且更稳定. 在 MAE 评价指标方面, 在平静期和磁暴期, SLSTM 模型的预测结果均比 LSTM 模型更佳.

表 3 中结果表明, SLSTM 模型在平静期和磁暴期预测结果的平均 RMSE 分别为 2.5 TECU 和 2.8 TECU, LSTM 模型的则为 3.6 TECU 和 4.3 TECU, SLSTM 模型预测结果的 RMSE 分别比 LSTM 模型低 31% 和 35%.

综上所述, SLSTM 模型的 MAE 和 RMSE 均优于传统 LSTM 模型, 证明了新模型的预报精度更高, 且具有更可靠的稳定性. 此外, 对比数据还发现在地磁活动剧烈时, 即使 TEC 极不稳定, 改进的 SLSTM 模型也能捕捉到 TEC 变化特性, 模型预报性能更优越.

实际上, 在 TEC 预报中, 经常面临的是从平静到磁暴、磁暴到平静的空间天气变化, 为直观评估 SLSTM 模型的预测效果, 选取云南边界 4 个格网 (95°E, 20°N; 95°E, 30°N; 110°E, 20°N; 110°E, 30°N). 分别对 2022 年磁暴期、平静期和下半年 (包含从平静到磁暴、磁暴到平静的连续不断的 TEC 数据, 其中有 19 个磁暴事件, 对应 Dst 如图 4 红框部分) 的




图 5 20 个格网对应地理位置

Fig. 5 Geographical locations corresponding to 20 grids




图 6 不同模型预报效果

Fig. 6 Effectiveness of different model forecasts

TEC 作为输入数据输入 SLSTM 模型和传统 LSTM 模型中, 对未来 12 h 的 TEC 进行预测, 并与被广泛应用的神经网络模型——BP 神经网络^[25,26] 的预测结果进行比较. 表 4 为三个模型预报结果的 RMSE 均值和 MAE 均值. 从表中可以看出, SLSTM 模型在平静期、磁暴期和下半年的预测效果都比传统 LSTM

模型、BP 模型更好. SLSTM 模型的 RMSE 均值在 2.7~2.8 TECU, LSTM 模型、BP 模型的 RMSE 均值分别为 3.7~5.0 TECU 和 3.7~5.1 TECU; 三个模型的 MAE 均值分别为 2.0~2.2 TECU, 3.1~4.0 TECU, 3.3~4.2 TECU. 分析结果表明 SLSTM 模型的预测精度和稳定性都比 LSTM 模型和 BP 模




图 7 平静期各模型预报残差
Fig. 7 Residuals of model forecasts in the quiet period




图 8 磁暴期各模型预报残差
Fig. 8 Residuals of model forecasts in the magnetic storms periods

表 2 SLSTM/LSTM 模型对 20 个格网预测结果的 MAE (单位: TECU)								
Table 2 MAE of SLSTM/LSTM model for prediction results of 20 grids (Unit: TECU)								
纬度/(°)N	经度/(°)E (平静期)				经度/(°)E (磁暴期)			
	95	100	105	110	95	100	105	110
30	2.9/2	1.0/1.8	1.4/2.4	2.0/2.4	2.7/3.4	3.5/3.8	2.1/2.6	2.8/2.8
27.5	1.6/2.1	1.4/3.3	1.6/2.4	3.3/2.8	2.7/3.4	1.6/2.9	1.6/2.6	3.5/2.9
25	2.6/3.2	3.4/2.3	2.2/3.2	1.6/4.6	3.3/3.6	3.2/3.4	2.1/2.8	2.4/3.9
22.5	1.6/3.1	1.5/2.5	2.1/1.9	3.4/2.6	1.1/4.1	1.7/2.3	2.2/2.7	2.1/3.3
20	1.1/4	1.5/3	2.8/3.0	2.2/4	2.2/5.7	2.0/3.8	2.9/3.3	1.2/4
均值	2.1/2.8				2.3/3.4			

表 3 SLSTM/LSTM 模型对 20 个格网预测结果的 RMSE (单位: TECU)								
Table 3 RMSE of SLSTM/LSTM model for prediction results of 20 grids (Unit: TECU)								
纬度/(°)N	经度/(°)E (平静期)				经度/(°)E (磁暴期)			
	95	100	105	110	95	100	105	110
30	3.5/2.5	1.3/2.3	2.4/2.7	3.1/2.8	3.6/4.3	4.0/4.6	3.1/3.4	3.6/3.7
27.5	1.9/2.4	2.1/3.7	2.2/3.3	3.8/3.7	3.4/4.5	2.5/3.3	1.7/3.2	4.3/4.1
25	3.2/3.7	4.0/3.2	3.2/4	1.9/5.5	3.8/4.5	3.7/4.3	2.3/3.5	2.8/4.9
22.5	1.7/3.8	1.7/3.5	2.5/2.4	3.7/3.4	1.5/5.2	1.8/3.1	2.6/3.7	2.7/4.1
20	1.2/4.7	1.6/4.3	3.1/4	3.2/5.1	2.8/7.1	2.1/4.8	3.0/4.6	1.4/5.2
均值	2.5/3.6				2.8/4.3			

表 4 SLSTM, LSTM, BP 模型对 4 个格网预测结果的 RMSE 均值和 MAE 均值 (单位: TECU)
Table 4 RMSE and MAE mean values by SLSTM, LSTM and BP models for
the prediction results of four grids (Unit: TECU)

模型	RMSE均值			MAE均值		
	平静期	磁暴期	下半年	平静期	磁暴期	下半年
SLSTM	2.7	2.8	2.7	2.0	2.2	2.1
LSTM	3.7	5.0	3.8	3.1	4.0	3.3
BP	3.7	5.1	4.0	3.3	4.2	3.6

型要好; 另外, 对于同一个模型分别对平静期、磁暴期和下半年 TEC 预测的精度分析, 平静期预测精度略高于下半年预测精度, 磁暴期预测精度最差, 这与以往的研究结果基本一致^[27].

3 结论

为了准确预报云南及周边地区的 TEC, 通过 LSTM 联合滑动窗口的方法, 采用前 5 天 TEC 值作为输入数据 (其中输入数据序列的最后 10% 用之前的预测值代替) 构建模型, 然后对未来 12 h 进行预报. 基于云南及其周边范围格网的 TEC 进行模型验证, 得出以下结论.

滑动窗口法在一定时间内可有效降低模型预测误差, 但随时间推移, 累积误差有所增大. 通过 LSTM 联合滑动窗口, 将长时序划分为短时序能减少累积误差, 可有效提高模型预测精度.

对云南省 20 个格网 TEC 预测结果分析发现: SLSTM 模型在平静期、磁暴期的平均 MAE、RMSE 和残差明显小于传统 LSTM 模型, 并且分布更集中. 其精度明显比传统 LSTM 模型更高, 且具有更好的稳定性和可靠性. 两种模型在平静期预报精度均比磁暴期高, SLSTM 模型比传统 LSTM 模型的预报精度高, 有更好的适用性, 尤其在磁暴期, 其预报精度相比于其他模型的提升相对平静期更明显.

利用 SLSTM 模型、LSTM 模型、BP 模型对 4 个抽样格网平静期、磁暴期和下半年的 TEC 进行预测, 结果显示: SLSTM 模型的 MAE 均值、RMSE 均值明显比 LSTM 模型、BP 模型都要小; 平静期预测精度略高于下半年, 而明显优于磁暴期的预测精度.

本研究可为云南及周边地区提供较高精度的 TEC 预测, 有望提升卫星导航定位电离层延迟改正的效果, 此外, 也展现了 SLSTM 模型在预测云南及

其周边电离层平静期和磁暴期的可靠性, 可为预报 TEC 提供参考.

参考文献

[1] YAO Y B, LIU L, KONG J, *et al.* Global ionospheric modeling based on multi-GNSS, satellite altimetry, and Formosat-3/COSMIC data[J]. *GPS Solutions*, 2018, **22**(4): 104

[2] YUAN Yumbin, LI Min, HUO Xingliang, *et al.* Research on performance of BeiDou global broadcast ionospheric delay correction model (BDGIM) of BDS-3[J]. *Acta Geodaetica et Cartographica Sinica*, 2021, **50**(4): 436-447 (袁运斌, 李敏, 霍星亮, 等. 北斗三号全球导航卫星系统全球广播电离层延迟修正模型 (BDGIM) 应用性能评估 [J]. 测绘学报, 2021, **50**(4): 436-447)

[3] ZHU Wei, REN Xiaodong, ZHANG Xiaohong. Performance of PPP-RTK enhanced by slant ionospheric model based on reference stations with different latitudes and distances[J/OL]. *Geomatics and Information Science of Wuhan University*, (2024-06-22). <https://doi.org/10.13203/j.whugis20230476>

[4] CHENG Huhua, ZHAN Caiju, ZHAO Liang, *et al.* Accuracy analysis of IRI2016 international reference ionosphere at altitude of 60~100 km[J]. *Acta Geodaetica et Cartographica Sinica*, 2020, **49**(1): 42-54 (程胡华, 詹彩菊, 赵亮, 等. IRI2016 参考电离层模型在高度 60~100 km 的精度分析 [J]. 测绘学报, 2020, **49**(1): 42-54)

[5] QIAO J D, LIU Y, FAN Z Q, *et al.* Ionospheric TEC data assimilation based on Gauss-Markov Kalman filter[J]. *Advances in Space Research*, 2021, **68**(10): 4189-4204

[6] CHEN Yutian, LIU Lilong, LIU Zhongliu, *et al.* Analysis of the influence of latitude factors on seasonal time series TEC short-term forecast model[J]. *Journal of Geodesy and Geodynamics*, 2018, **38**(6): 581-586 (陈雨田, 刘立龙, 刘中流, 等. 纬度因素对季节性时序 TEC 短期预报模型的影响分析 [J]. 大地测量与地球动力学, 2018, **38**(6): 581-586)

[7] YIN Ping, YAN Xiaopeng, NING Zehao. A combined forecasting method of ionospheric tomography TEC based on LSTM and IRI model[J]. *Chinese Journal of Radio Science*, 2022, **37**(5): 852-861 (尹萍, 闫晓鹏, 宁泽浩. 一种基于 LSTM 与 IRI 模型的电离层层析 TEC 组合预测方法 [J]. 电波科学学报, 2022, **37**(5): 852-861)

- [8] ZHANG Fubin, ZHOU Chen, WANG Cheng, *et al.* Global ionospheric TEC prediction based on deep learning[J]. *Chinese Journal of Radio Science*, 2021, **36**(4): 553-561 (张富彬, 周晨, 王成, 等. 基于深度学习的全球电离层 TEC 预测 [J]. 电波科学学报, 2021, **36**(4): 553-561)
- [9] TANG R X, ZENG F T, CHEN Z, *et al.* The comparison of predicting storm-time ionospheric TEC by three methods: ARIMA, LSTM, and Seq2Seq[J]. *Atmosphere*, 2020, **11**(4): 316
- [10] TANG Siyu, HUANG Zhi. Prediction of ionospheric total electron content based on causal convolutional and LSTM network[J]. *Chinese Journal of Space Science*, 2022, **42**(3): 357-365 (唐丝语, 黄智. 基于因果卷积与 LSTM 网络的电离层总电子含量预报 [J]. 空间科学学报, 2022, **42**(3): 357-365)
- [11] XIE T, DAI Z Q, ZHU X W, *et al.* LSTM-based short-term ionospheric TEC forecast model and positioning accuracy analysis[J]. *GPS Solutions*, 2023, **27**(2): 66
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural computation*, 1997, **9**(8): 1735-1780
- [13] LIU Weifeng, HUANG Jiang, DENG Baichang, *et al.* Calculation analysis of ionospheric irregularity zonal drift velocity in Guangzhou based on GPS measurements[J]. *Chinese Journal of Space Science*, 2012, **32**(1): 48-54 (刘伟峰, 黄江, 邓柏昌, 等. 基于 GPS 的广州地区电离层不规则体纬向漂移速度计算分析 [J]. 空间科学学报, 2012, **32**(1): 48-54)
- [14] KAREVAN Z, SUYKENS J A K. Transductive LSTM for time-series prediction: an application to weather forecasting[J]. *Neural Networks*, 2020, **125**: 1-9
- [15] HAO Yichen, XIE Xinyu, DING Jiaqi, *et al.* Spatiotemporal prediction method for the transient multiphase flow field via graph neural network[J]. *Journal of Harbin Engineering University*, 2024, **45**(9): 1761-1769 (郝伟琛, 谢心喻, 丁家琦, 等. 瞬态多相流场图神经网络时空预测方法研究 [J]. 哈尔滨工程大学学报, 2024, **45**(9): 1761-1769)
- [16] ZHAO Xinyao. Beidou/Accelerometer Fusion Dynamic Analysis and Early Warning[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2023
- [17] XIE Ting, CHEN Biyan, KUANG Cuilin. Study of ionospheric anomaly detection method combining PCA and sliding time window[J]. *Journal of Geodesy and Geodynamics*, 2021, **41**(10): 1085-1094 (谢婷, 陈必焰, 匡翠林. 结合 PCA 和滑动时窗的电离层异常探测方法研究 [J]. 大地测量与地球动力学, 2021, **41**(10): 1085-1094)
- [18] TANG Wang, MA Shangchang, LI Cheng. LSTM ground temperature prediction method based on sliding window[J]. *Journal of Chengdu University of Technology (Science & Technology Edition)*, 2021, **48**(3): 377-384 (唐旺, 马尚昌, 李程. 基于滑动窗口的 LSTM 地温预测方法 [J]. 成都理工大学学报 (自然科学版), 2021, **48**(3): 377-384)
- [19] ZHANG X H, REN X D, WU F B, *et al.* Short-term prediction of ionospheric TEC based on ARIMA model[J]. *Journal of Geodesy and Geoinformation Science*, 2019, **2**(1): 9-16
- [20] LIU Lilong, CHEN Yutian, LI Junyu, *et al.* Short-term prediction and applicability analysis of regional ionospheric total electron content in active period[J]. *Geomatics and Information Science of Wuhan University*, 2019, **44**(12): 1757-1764 (刘立龙, 陈雨田, 黎峻宇, 等. 活跃期区域电离层总电子短期预报及适用性分析 [J]. 武汉大学学报 (信息科学版), 2019, **44**(12): 1757-1764)
- [21] DUNCAN R A. The equatorial *F*-region of the ionosphere[J]. *Journal of Atmospheric and Terrestrial Physics*, 1960, **18**(2/3): 89-100
- [22] GONZALEZ W D, JOSELYN J A, KAMIDE Y, *et al.* What is a geomagnetic storm?[J]. *Journal of Geophysical Research: Space Physics*, 1994, **99**(A4): 5771-5792
- [23] REN X D, YANG P X, MEI D K, *et al.* Global ionospheric TEC forecasting for geomagnetic storm time using a deep learning-based multi-model ensemble method[J]. *Space Weather*, 2023, **21**(3): e2022SW003231
- [24] MUHAMMAD A, KÜLAHCI F. A semi-supervised total electron content anomaly detection method using LSTM-auto-encoder[J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2022, **241**: 105979
- [25] SHI S S, ZHANG K F, SHI J Q, *et al.* Modeling TEC maps over China using particle swarm optimization neural networks and long-term ground-based GPS, COSMIC, and Fengyun data[J]. *Space Weather*, 2023, **21**(4): e2022SW003357
- [26] ZHANG L, WANG F L, SUN T, *et al.* A constrained optimization method based on BP neural network[J]. *Neural Computing and Applications*, 2018, **29**(2): 413-421
- [27] XIONG Bo, LI Xiaolin, WANG Yuqing, *et al.* Prediction of ionospheric TEC over China based on long and short-term memory neural network[J]. *Chinese Journal Geophysics*, 2022, **65**(7): 2365-2377 (熊波, 李肖霖, 王宇晴, 等. 基于长短期记忆神经网络的中国地区电离层 TEC 预测 [J]. 地球物理学报, 2022, **65**(7): 2365-2377)

作者简介



黄 灿 女, 1997 年 6 月出生于广西
壮族自治区钦州市, 桂林理工大学测绘地理
信息学院在读硕士研究生, 主要研究方向为
电离层参数预测方法。
E-mail: can_huangcc@163.com



黎峻宇 (通信作者) 男, 1989 年
2 月出生于广西壮族自治区玉林市, 现为桂
林理工大学测绘地理信息学院副教授,
硕士生导师, 主要从事 GNSS 空间环境监
测研究。
E-mail: yl_lijunyu@163.com