

ZHU Jiahao, YAN Wenlin, JIN Yufeng, YAN Taiming, WANG Jian. Comparative Analysis of Four Neural Network Methods for TEC Modeling during Ionospheric Magnetic Storms (in Chinese). *Chinese Journal of Space Science*, 2025, 45(5): 1230–1242. CSTR:32142.14.cjss.2024-0087. DOI:10.11728/cjss2025.05.2024-0087

四种神经网络方法在电离层磁暴期 TEC 建模的对比分析*

朱佳豪¹ 闫文林¹ 金字峰¹
严泰明¹ 王 坚²

1(江苏师范大学地理测绘与城乡规划学院 徐州 221116)

2(北京建筑大学测绘与城市空间信息学院 北京 102616)

摘 要 电离层总电子含量 (TEC) 是描述电离层的重要参数, 然而电离层经验模型对于磁暴期 TEC 的预测精度不够理想. 针对这个问题, 使用 LSTM、BiLSTM、结合注意力机制的卷积神经网络-长短期记忆 (CNN-LSTM-Attention) 以及结合注意力机制的卷积神经网络-双向长短期记忆 (CNN-BiLSTM-Attention) 神经网络模型进行电离层 TEC 预报的研究. 根据 $Dst \leq -30$ nT 的标准, 确定了 2004–2022 年发生磁暴的时间段. 在此基础上, 结合多种时空参数 (UTS 与 UTC, SA 与 AA, CHS 与 SHS), 得到了 4 种适用于磁暴期 TEC 的预测模型. 利用 2023 年磁暴期的 TEC 对四种模型的精度和可靠性进行验证. 结果表明, CNN-BiLSTM-Attention 模型的预测效果明显优于其他三种模型, 其绝对平均误差 (MAE) 为 0.882~5.270 TECU, 均方根误差 (RMSE) 为 1.175~6.983 TECU, 且预测结果与参考值之间存在较强的相关性, 决定系数 (R^2) 均在 0.7 以上. 此外, 该模型拟合函数的斜率整体最接近于 1, 同样优于其他三种模型的拟合效果.

关键词 电离层磁暴期, 电离层总电子含量, 长短期记忆网络, 卷积神经网络, 注意力机制

中图分类号 P352

Comparative Analysis of Four Neural Network Methods for TEC Modeling during Ionospheric Magnetic Storms

ZHU Jiahao¹ YAN Wenlin¹ JIN Yufeng¹
YAN Taiming¹ WANG Jian²

1(School of Geography, Geomatics and Planning, Jiangsu Normal University, Xuzhou 221116)

2(School of Geomatics and Urban Spatial Informatics, Beijing University of Civil Engineering and Architecture, Beijing 102616)

* 国家自然科学基金项目 (42274029) 和江苏省自然科学基金项目 (BK20181015) 共同资助

2024-07-04 收到原稿, 2024-12-16 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/>)

Abstract The Total Electron Content (TEC) of the ionosphere is an important parameter for describing the ionosphere activities, and much research has been done for the accurate methods for the ionospheric TEC prediction. However, the prediction accuracy of ionospheric empirical models for TEC during geomagnetic storms is still not ideal. To address this issue, this paper aims to assess the performance of ionospheric TEC predicting methods, which involve the LSTM, the BiLSTM, the Convolutional Neural Network-Long Short-Term Memory combined with Attention mechanism (CNN-LSTM-Attention), and the Convolutional Neural Network-Bidirectional Long Short-Term Memory combined with Attention mechanism (CNN-BiLSTM-Attention). At first, the geomagnetic storm periods are identified by comparing with the threshold of *Dst* index (≤ -30 nT), during the years from 2004 to 2022. Then, four neural network models for the ionospheric TEC prediction are formed, through the combinations of multiple spatiotemporal parameters, such as UTS, UTC, SA, AA, CHS, and SHS. Finally, the accuracy and reliability of the four neural network models are assessed using the reference TEC dataset collected during geomagnetic storms in 2023, and three statistical index, Mean Absolute Error (MAE), The Root Mean Square Error (RMSE), and coefficient of determination R^2 , are utilized. The results show that, the performance of the CNN-BiLSTM-Attention model is superior to the other three models, with MAE ranging from 0.882 to 5.270 TECU, RMSE between 1.175 and 6.983 TECU, and R^2 values exceeding 0.7. In order to better describe the difference between the predicted values and the reference values, the scatter plots of two datasets are plotted for the fitting of linear regression equations. The slope of fitted function from CNN-BiLSTM-Attention model is very close to the ideal value 1, also indicating a better performance compared to the other models.

Key words Ionospheric magnetic storm period, Total electron content of ionosphere, Long short-term memory, Convolutional neural network, Attention mechanism

0 引言

电离层总电子含量 (TEC) 是描述电离层形态变化的最重要的参数, 研究可靠的 TEC 预报模型, 增强对电离层活动的监测及预报的能力, 对把握电离层时空变化特征, 进而指导人类生产生活具有重要的意义^[1-3].

电离层经验模型被广泛地运用于 TEC 的预报^[4]. 其中国际参考电离层模型 (IRI) 被广泛使用, 该模型同时采用了电离层测高仪、卫星和火箭探测、非相干散射雷达等多重探测数据^[5]. 此外, 由于人工神经网络能够描述复杂的非线性关系, 因此该技术目前也成为电离层预报的重要手段. 例如, Feng 等^[6]利用傅里叶变换与长短期记忆网络 (LSTM) 模型结合的方法, 得到 TEC 偏差与太阳活动周期之间具有强相关性的结论. Tang 和 Huang^[7]利用因果卷积和 LSTM 网络模型的方法, 将 LSTM 模型的精度提高了 15%. Tang 等^[8]利用基于麻雀搜索算法, 改进了 Elman 神经网络的 TEC 短期预报模型, 计算结果与参考值的相关性提高到 0.976. Liu 等^[9]引入注意力机制与 LSTM 融合的方法, 使预测拟合度超过了 0.95. Wu

等^[10]利用奇异谱分析融合 LSTM 的方法, 使电离层 TEC 短期预报模型的精度提高了 4%. Tang 等^[11]利用结合注意力机制的卷积神经网络-长短期记忆 (CNN-LSTM-Attention) 神经网络改进了 TEC 预报模型, 使其均方根误差达到了 1.87 TECU. Chen 等^[12]利用非线性最小二乘拟合待定系数的方法, 提出了一种新的多参数经验模型, 实验结果表明该模型精度优于 IRI-2020 和 NeQuick2 u 模型. 然而, Ma 等^[13]指出利用电离层经验模型对于磁暴期内的精度不够理想, 并提出利用一种新的混合框架 Neural Prophet 神经网络预报模型, 精度相对于 LSTM 模型提高了 13.3%.

因此, 同样针对电离层经验模型在磁暴期内精度不够理想的问题, 本文利用 LSTM、双向长短期记忆网络 (BiLSTM)、CNN-LSTM-Attention 以及结合注意力机制的卷积神经网络-双向长短期记忆 (CNN-BiLSTM-Attention) 四种神经网络模型, 对近 20 年的时空数据进行训练, 构建起适用于磁暴期的 TEC 预测模型. 然后, 利用太阳活动高年 (2023 年) 磁暴期的 TEC 实测数据, 对构建的预测模型进行对比分析.

1 神经网络模型

LSTM, BiLSTM, CNN-LSTM-Attention, CNN-BiLSTM-Attention 是目前研究中比较常用的神经网络模型.

1.1 LSTM 和 BiLSTM

电离层 TEC 数据是一种典型的时间序列数据, 而 LSTM 模型具备长时间序列数据的处理能力、良好的学习能力以及防止梯度爆炸和梯度消失的能力^[9]. 一个 LSTM 单元由遗忘门、输入门和输出门三部分构成.

遗忘门的目的是根据先前输出向量和当前输入向量来确定留下哪些向量. 遗忘门输出 f_t 为^[10]

$$f_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f). \quad (1)$$

其中, σ 为 Sigmoid 函数, $\mathbf{W}_f$ 为遗忘门的权重矩阵, $\mathbf{b}_f$ 为遗忘门的偏差向量, $\mathbf{h}_{t-1}$ 为 $t-1$ 时刻的隐藏状态向量, $\mathbf{x}_t$ 为 t 时刻的输入向量, $[\mathbf{h}_{t-1}, \mathbf{x}_t]$ 表示将两个向量连接成一个更长的向量, $(\cdot)$ 表示点乘.

输入门确定哪些向量需要被更新, 并将更新过的向量输入到新的单元格中. 输入门输出为^[10]

$$i_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i). \quad (2)$$

其中, $\mathbf{W}_i$ 为输入门的权重矩阵, $\mathbf{b}_i$ 为输入门的偏差向量.

输出门决定输出哪些向量. 输出门的输出为^[9]

$$O_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o). \quad (3)$$

其中, $\mathbf{W}_o$ 为输出门的权重矩阵, $\mathbf{b}_o$ 为输出门的偏差向量. t 时刻的隐藏状态为^[9]

$$\mathbf{h}_t = O_t * \tanh(\mathbf{C}_t). \quad (4)$$

其中, $(*)$ 代表哈达玛积, $\tanh$ 为激活函数, $\mathbf{C}_t$ 为神

经元状态信息, 表达式为^[10]

$$\mathbf{C}_t = (\mathbf{f}_t * \mathbf{C}_{t-1}) + (\mathbf{i}_t * \tilde{\mathbf{C}}_t). \quad (5)$$

其中, $\mathbf{C}_{t-1}$ 为 $t-1$ 时刻的单元状态, $\tilde{\mathbf{C}}_t$ 为当前输入的单元状态, 其表达式为^[9]

$$\tilde{\mathbf{C}}_t = \sigma(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c). \quad (6)$$

其中, $\mathbf{W}_c$ 为当前神经元下的权重矩阵, $\mathbf{b}_c$ 为当前神经元下的偏差向量.

LSTM 模型只有一个后向 LSTM 单元, 用来处理时间序列中前一时刻的信息, 而 BiLSTM 则是由两个独立的 LSTM 单元组成, 分别负责处理前一时刻和后一时刻的信息.

与 LSTM 模型相比, BiLSTM 模型在中增加了反向 LSTM 的计算, 将先前的信息和以后的信息都作为当前信息的基础, 因此预测表现理论上会优于单向 LSTM^[14,15].

1.2 CNN-LSTM-Attention 和 CNN-BiLSTM-Attention

CNN-LSTM-Attention 和 CNN-BiLSTM-Attention 两种模型均由卷积神经网络 (CNN) 模型、数据处理模块和基于注意力机制模块三部分构成, 详细流程如图 1 所示. 可以看出, 两种模型的主要区别在于数据处理模块采用的是 LSTM 模型还是 BiLSTM 模型.

(1) CNN 模型. 其核心是卷积操作, 实现方法是将数据与一组固定权重的滤波矩阵进行内积的操作, 进而提取数据中的相关特征. 如图 1 所示, CNN 模型由输入层、卷积层、池化层和全连接层四部分组成. 卷积层的功能是通过对输入数据进行卷积操作, 识别和提取出输入数据的不同特征, 并进行权重差异化分配, 然后使用 ReLU 激活函数对卷积后的值进行处理




图 1 CNN-LSTM-Attention 和 CNN-BiLSTM-Attention 模型流程

Fig. 1 Flow of CNN-LSTM-Attention and CNN-BiLSTM-Attention model

并输出至池化层^[15]. 池化层的功能是对经卷积层提取的特征进行选择和信息过滤, 在压缩数据维度的同时, 保留数据特性, 主要包括最大池化和平均池化两种方法^[16].

(2) 数据处理模块. 该模块利用 LSTM 或 BiLSTM 模型对第一步经过 CNN 模型处理得到的数据, 进行下一步基于神经网络模型的计算.

(3) 基于注意力机制模块. 注意力机制方法是在模拟人类大脑处理事情时, 将注意力多集中于重要内容, 忽略其他次要信息的过程. 该方法通过映射权重和参数学习为 LSTM 或 BiLSTM 模型的输出值分配不同的权重, 加强了重要信息的影响力^[15].

2 实验与数据

在全球范围内选取 8 个测站的 TEC 观测数据, 对四种神经网络方法在电离层磁暴期 TEC 建模的精度进行对比分析. 其中位于低纬度地区的分别是 AS00Q 站(7.95°S, 14.4°W)、CAJ2M 站(22.7°S, 45°W)和 FZA0M 站(3.9°S, 38.24°W); 位于中纬度地区的分别是 AT138 站(28°N, 23.5°E)、BC840 站(40°N, 105.3°W)和 RL052 站(51.5°N, 0.6°W); 位于高纬度的分别是 GA762 站(62.38°N, 145°W)和 TR169 站(69.6°N, 19.2°E).

电离层 TEC 受太阳活动、地磁活动等因素的共同影响, 且随昼夜、季节变化而发生周期性变化. 本文研究的模型包含 UTS、UTC、AA、SA、SHS、CHS、 $F_{10.7}$ 指数、SNN 指数、 Dst 指数、 K_p 指数和 TEC, 共计 11 种数据. 其中地方时的正弦值 (UTS) 和余弦值 (UTC) 是两组与当地地方时有关的参数, 可以用于计算电离层日变化的大致情况^[17]; 年异常 (AA)、半年异常 (SA) 是两组与年积日有关的参数, 用于计算电离层季节变化的情况^[18]. 太阳天顶角的正弦值 (SHS) 和余弦函数 (CHS), 用于反映地球运动于电离层的影响^[19]. 本文研究的磁暴期 TEC 模型还涉及太阳活动指数中的 10.7 cm 射电流量指数 $F_{10.7}$ 、太阳黑子数 (SNN) 以及地磁指数中的低纬地磁水平分量的强度变化 (Dst) 和磁情指数 (K_p), 这些指数来源于美国航空航天局 (NASA), 分辨率为 1 h. 其中 Dst 指数是构建磁暴期 TEC 模型的重要指数, 是反映地磁活动强弱的重要指标. 全国标准信息公共服务

平台提供的《地磁活动水平分级 (QX/T 239—2014)》标准中给出了 Dst 指数与地磁活动水平的关系, 如表 1 所示.

图 2 给出了 2023 年 Dst 指数的小时变化, 结合表 1 可以判读, 全年有 1 次特大磁暴 ($Dst \leq -200$ nT), 有 4 次大磁暴 ($Dst \leq -100$ nT), 还有多场中小磁暴 ($Dst \leq -30$ nT). 因此, 2023 年的磁暴数据非常典型, 非常适合用于本文预报模型的验证.

2.1 实验数据与数据预处理

从全球电离层无线电观测台 (GIRO) 的数据网站*下载 2004—2023 年磁暴期利用电离层测高仪数据外推的 TEC 数据, 时间分辨率为 1 h. 建立基于 LSTM 网络的 TEC 模型 (模型 1)、基于 BiLSTM 网络的 TEC 模型 (模型 2)、基于 CNN-LSTM-Attention 网络的 TEC 模型 (模型 3) 以及基于 CNN-BiLSTM-Attention 网络的 TEC 模型 (模型 4). 最后, 利用 2004—2022 年磁暴期的数据进行建模, 用于预测 2023 年磁暴期的 TEC.

表 1 Dst 指数与地磁活动关系
Table 1 Relationship between Dst index and geomagnetic activity

Dst 指数/nT	地磁情况
$Dst > -30$	地磁平静期
$-50 < Dst \leq -30$	微小磁暴
$-100 < Dst \leq -50$	中等磁暴
$-200 < Dst \leq -100$	大磁暴
$Dst \leq -200$	特大磁暴




图 2 2023 年 Dst 指数小时变化

Fig. 2 Dst index hourly variation in 2023

* <https://giro.uml.edu/didbase/scaled.php>

2.2 实验环境与模型参数设置

以 CNN-BiLSTM-Attention 模型为例, 具体模型参数与训练方案如下.

第 1 步 添加一个具有 32 通道的一维卷积层, 过滤器的大小为 3, 使用 ReLU 函数激活.

第 2 步 利用已激活数据再次进行卷积, 添加一个具有 64 通道的一维卷积层, 过滤器的大小为 3, 使用 ReLU 函数激活.

第 3 步 进行全局平均池化.

第 4 步 进行 BiLSTM 模型的训练, 该模型的维度设置为 64, 其中激活函数采用 softmax.

第 5 步 点乘注意力机制.

另外, 模型使用 Adam 优化器和均方根误差作为损失函数进行编译. 该模型共进行 100 个周期的训练, 批量大小为 50. 其余模型与 CNN-BiLSTM-Attention 模型采用相同的设定.

2.3 实验评价指标

利用 2023 年磁暴期 TEC 实测值, 对预测值的精度和可靠性进行评估. 评估模型的精度通常采用绝对

平均误差 (MAE, E_{MAE})、均方根误差 (RMSE, E_{RMSE}) 和决定系数 (R^2) 等指标. 上述三个指标的表达式分别为^[20]

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (7)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (8)$$

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (9)$$

其中, y_i 为模型预测 TEC, $\hat{y}_i$ 为实测 TEC.

3 结果与分析

3.1 低纬度地区磁暴期 TEC 预测结果分析

低纬度地区测站 (AS00Q, CAJ2M, FZA0M) 四种模型预测 TEC 的残差如图 3 所示, 可以看出, 四种模型的残差主要集中于 ± 20 TECU 之间. 其中模




图 3 2023 年磁暴期低纬度测站模型预测 TEC 残差

Fig. 3 TEC residuals predicted by the low latitude station model during the storms in 2023

型 1 为 LSTM 模型, 模型 2 为 BiLSTM 模型, 模型 3 为 CNN-LSTM-Attention 模型, 模型 4 为 CNN-BiLSTM-Attention 模型.

对四种模型的预测 TEC 与实测 TEC 之间的差异分别进行统计, 结果列于表 2. 可以看出, CNN-BiLSTM-Attention 模型的精度最好, 其 MAE 最低

为 3.303 TECU, RMSE 最低为 4.116 TECU, R^2 最高为 0.932.

3.2 中纬度地区磁暴期 TEC 预测结果分析

中纬度地区测站 (AT138, BC840, RL052) 四种模型预测 TEC 的残差如图 4 所示. 可以看出四种模型的残差主要集中于 ± 10 TECU 之间.

表 2 低纬度测站模型预测 TEC 的精度统计
Table 2 Accuracy of model prediction TEC at low latitude stations

站点	评价指标	LSTM	BiLSTM	CNN-LSTM-Attention	CNN-BiLSTM-Attention
AS00Q站	MAE/TECU	5.013	5.257	6.725	3.637
	RMSE/TECU	6.856	7.014	8.756	5.013
	R^2	0.871	0.865	0.790	0.931
CAJ2M站	MAE/TECU	4.126	4.304	3.666	3.303
	RMSE/TECU	5.124	5.472	4.604	4.116
	R^2	0.888	0.890	0.917	0.931
FZA0M站	MAE/TECU	5.809	6.156	5.931	5.270
	RMSE/TECU	7.602	7.976	7.695	6.983
	R^2	0.920	0.912	0.918	0.932




图 4 2023 年磁暴期中纬度测站模型预测 TEC 残差

Fig. 4 TEC residuals predicted by the middle latitude station model during the storms in 2023

对四种模型的预测 TEC 与实测 TEC 之间的差异分别进行统计, 结果列于表 3. 可以看出, CNN-BiLSTM-Attention 模型的精度最好, 其 MAE 最低为 1.482 TECU, RMSE 最低为 2.132 TECU, R^2 最高为 0.961.

3.3 高纬度地区磁暴期 TEC 预测结果分析

高纬度地区测站 (GA762 和 TR169) 四种模型预测 TEC 的残差如图 5 所示, 与实测 TEC 之间差异的统计如表 4 所示.

结合图 5 和表 4 可以看出, 四种模型的精度接

近, 四种模型残差的绝对值均小于 10 TECU. 其中, CNN-BiLSTM-Attention 模型的精度最优, 该模型的 MAE 最低为 0.882 TECU, RMSE 最低为 1.175 TECU, R^2 最高为 0.940.

3.4 拟合回归分析

为了更好地描述预报值与实测值的差异, 绘制了上述 8 个测站 TEC 预测值和参考值的散点图, 并且得到线性回归方程, 如图 6~13 所示. 图 6~8 为四种模型在低纬度地区测站 (AS00Q, CAJ2M, FZA0M) 的 TEC 预测值与参考值的散点图, 其中 CNN-BiL-

表 3 中纬度测站模型预测 TEC 的精度统计
Table 3 Accuracy of model prediction TEC at middle latitude stations

站点	评价指标	LSTM	BiLSTM	CNN-LSTM-Attention	CNN-BiLSTM-Attention
AT138站	MAE/TECU	2.150	1.896	2.001	1.482
	RMSE/TECU	2.672	2.399	2.528	2.132
	R^2	0.938	0.950	0.945	0.961
BC840站	MAE/TECU	2.385	2.856	2.533	1.494
	RMSE/TECU	3.522	3.832	3.752	2.158
	R^2	0.897	0.878	0.883	0.961
RL052站	MAE/TECU	2.082	3.702	1.774	1.529
	RMSE/TECU	2.778	5.089	2.284	2.177
	R^2	0.617	0.363	0.759	0.765




图 5 2023 年磁暴期高纬度测站模型预测 TEC 残差
Fig. 5 TEC residuals predicted by the high latitude station model during the storms in 2023

STM-Attention 模型在三个站拟合函数的斜率分别为 1.005, 0.977, 0.900 (图 6~8 中的模型 4).

图 9~11 为四种模型在中纬度地区三个测站(AT138, BC840, RL052)的 TEC 预测值和参考值的散点. 其中 CNN-BiLSTM-Attention 模型在三个测站拟合函数的斜率分别为 0.977, 0.987, 0.931 (图 9~11 中的模型 4).

图 12 和图 13 为四种模型在高纬度地区两个测站(GA762 和 TR169)的 TEC 预测值和参考值的散点. 其中, CNN-BiLSTM-Attention 模型两个测站拟合函数的斜率分别为 0.822 和 0.978 (图 12 和图 13 中的模型 4).

有研究表明, 拟合函数的斜率越接近于 1, 模型的拟合效果越好^[7]. 因此, 由图 6~13 可知, 四种模型中, CNN-BiLSTM-Attention 模型拟合函数的斜率整体最接近于 1, 该模型的拟合效果最好. 结合表 2~4 可以清晰看出, CNN-BiLSTM-Attention 模型的 MAE 为 0.882~5.270 TECU, RMSE 为 1.175~6.983 TECU, 同时该模型预测值与参考值之间存在较强的相关性, R^2 均大于 0.7, 且该模型拟合函数的斜率整体最接近于 1, 优于其他三种模型的拟合效果; 四种模型均呈现出中高纬度地区的精度较高, 随着纬度的降低, 预报精度下降的特点. 这是因为磁暴期内, 与中高纬度地区相比, 低纬度地区电离层

表 4 高纬度测站模型预测 TEC 的精度统计
Table 4 Accuracy of model prediction TEC at high latitude stations

站点	评价指标	LSTM	BiLSTM	CNN-LSTM-Attention	CNN-BiLSTM-Attention
GA762站	MAE/TECU	1.291	1.472	1.116	1.033
	RMSE/TECU	1.765	2.069	1.489	1.341
	R^2	0.790	0.711	0.850	0.883
TR169站	MAE/TECU	1.288	1.233	1.254	0.882
	RMSE/TECU	1.750	1.678	1.709	1.175
	R^2	0.868	0.878	0.874	0.940




图 6 AS00Q 测站四种模型预报值与参考值的散点图

Fig. 6 Scatter-plot of the predicted values and the reference values of the four models of AS00Q station




图 7 CAJ2M 测站四种模型预报值与参考值的散点图

Fig. 7 Scatter-plot of the predicted values and the reference values of the four models of CAJ2M station




图 8 FZA0M 测站四种模型预报值与参考值的散点图

Fig. 8 Scatter-plot of the predicted values and the reference values of the four models of FZA0M station




图 9 AT138 测站四种模型预报值与参考值的散点图

Fig. 9 Scatter-plot of the predicted values and the reference values of the four models of AT138 station




图 10 BC840 测站四种模型预报值与参考值的散点图

Fig. 10 Scatter-plot of the predicted values and the reference values of the four models of BC840 station




图 11 RL052 测站四种模型预报值与参考值的散点图

Fig. 11 Scatter-plot of the predicted values and the reference values of the four models of RL052 station




图 12 GA762 测站四种模型预报值与参考值的散点图

Fig. 12 Scatter-plot of the predicted values and the reference values of the four models of GA762 station




图 13 TR169 测站四种模型预报值与参考值的散点图

Fig. 13 Scatter-plot of the predicted values and the reference values of the four models of TR169 station

TEC 变化更加明显, 且受到风场、电场等作用的共同影响, 增加了模型对电离层时空信息的捕捉难度, 导致模型的精度整体下降. 因此, 通过该测试, 可以得出 LSTM, BiLSTM, CNN-LSTM-Attention 模型不如 CNN-BiLSTM-Attention 模型的结论.

4 结论与讨论

近两年为太阳活动高年, 磁暴现象发生频繁, 亟需可靠有效的电离层的预报手段. 本文研究分析了 LSTM, BiLSTM, CNN-LSTM-Attention, CNN-BiLSTM-Attention 四种神经网络模型对磁暴期的 TEC 进行预报的方法. 对 2004—2022 年磁暴期的多种时空数据进行训练, 得到适用于磁暴期 TEC 的预报模型. 利用 2023 年磁暴期 TEC 数据对得到的四种预报模型精度与可靠性进行验证. 结果表明, CNN-BiLSTM-Attention 模型具有最好的精度, 可以有效地对磁暴期的电离层 TEC 进行预报. 这是因为 CNN-BiLSTM-Attention 模型具备以下特点: BiLSTM 模型具有双向结构, 可以从前后两个时间维度同时运行网络, 并将两个方向的信息进行拼接或合

并, 因此, 相对于 LSTM 模型能更全面地理解和表示序列数据; 包含的注意力机制能对不同的输入值赋予不同的权重, 增强了重要信息的影响力, 使预报结果与实际值更加接近; CNN 模型能更为有效地提取数据间的空间特征, 使预报精度得到进一步提高.

本文主要基于测高仪数据探讨四种神经网络模型预测 TEC 的准确性与有效性, 计算结果主要反映电离层的总电子含量. 除电离层测高仪数据之外, GNSS-TEC 的方法在高精度 TEC 测量任务中也发挥重要的作用, 其计算结果还可以反映出等离子体层的总电子含量. 因此, GNSS-TEC 也是后续研究的重要方向. 在后续的研究中将收集更多的 TEC 数据, 扩展研究预测模型在其他复杂电离层环境下的适用性.

参考文献

- [1] YUAN Yunbin. Study on Theories and Methods of Correcting Ionospheric Delay and Monitoring Ionosphere Based on GPS[D]. Wuhan: Institute of Geodesy and Geophysics, Chinese Academy of Sciences, 2002
- [2] YUAN Yunbin, HUO Xingliang, ZHANG Baocheng. Research progress of precise models and correction for GNSS ionospheric delay in China over recent years[J]. *Acta*

- Geodetica et Cartographica Sinica*, 2017, **46**(10): 1364-1378 (袁运斌, 霍星亮, 张宝成. 近年来我国 GNSS 电离层延迟精确建模及修正研究进展 [J]. *测绘学报*, 2017, **46**(10): 1364-1378)
- [3] HAN Xihao, ZHENG Shuaiyong, YANG Jianlei, *et al.* Status and development of the ionospheric error correction techniques in satellite navigation[J]. *GNSS World of China*, 2024, **49**(2): 111-126 (韩喜豪, 郑帅勇, 杨建雷, 等. 卫星导航中电离层误差校正技术现状与发展 [J]. *全球定位系统*, 2024, **49**(2): 111-126)
- [4] ZHANG Ting. Study on Empirical Model of Ionospheric TEC Based on Multi-Source Data[D]. Zibo: Shandong University of Technology, 2023
- [5] ZHANG B B, WANG Z T, SHEN Y, *et al.* Evaluation of f_0F_2 and h_mF_2 parameters of IRI-2016 model in different latitudes over China under high and low solar activity years[J]. *Remote Sensing*, 2022, **14**(4): 860
- [6] FENG J D, ZHANG Y B, LI W, *et al.* Analysis of ionospheric TEC response to solar and geomagnetic activities at different solar activity stages[J]. *Advances in Space Research*, 2023, **71**(5): 2225-2239
- [7] 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)
- [8] TANG Jun, ZHONG Zhengyu, LI Yinjian, *et al.* Short-term prediction model of ionospheric TEC based on SSA-Elman neural network[J]. *Journal of Geodesy and Geodynamics*, 2022, **42**(4): 378-383 (汤俊, 钟正宇, 李垠健, 等. 基于 SSA-Elman 神经网络的电离层 TEC 短期预报模型 [J]. *大地测量与地球动力学*, 2022, **42**(4): 378-383)
- [9] LIU Haijun, LEI Dongxing, YUAN Jing, *et al.* Ionospheric TEC prediction based on Attention-LSTM[J]. *Chinese Journal of Geophysics*, 2024, **67**(2): 439-451 (刘海军, 雷东兴, 袁静, 等. 基于注意力机制 LSTM 的电离层 TEC 预测 [J]. *地球物理学报*, 2024, **67**(2): 439-451)
- [10] WU Han, HUANG Ling, LIU Lilong, *et al.* Short term prediction model of ionospheric TEC based on SSA-LSTM[J]. *Journal of Geodesy and Geodynamics*, 2022, **42**(6): 626-630,654 (吴晗, 黄玲, 刘立龙, 等. 基于 SSA-LSTM 的短期电离层 TEC 组合预报模型 [J]. *大地测量与地球动力学*, 2022, **42**(6): 626-630,654)
- [11] TANG J, LI Y J, DING M F, *et al.* An ionospheric TEC forecasting model based on a CNN-LSTM-Attention mechanism neural network[J]. *Remote Sensing*, 2022, **14**(10): 2433
- [12] CHEN Jianghe, XIONG Pan, WU Haochen, *et al.* A multi-parameter fusion forecast model of ionospheric TEC in the Beijing-Tianjin-Hebei region[J]. *Earthquake*, 2024, **44**(2): 12-32 (陈江河, 熊攀, 武浩琛, 等. 京津冀区域电离层 TEC 多参数融合预测模型 [J]. *地震*, 2024, **44**(2): 12-32)
- [13] MA Bin, HUANG Ling, WU Han, *et al.* Study on the NeuralProphet forecast TEC model over China during the severe geomagnetic storm in March 2015[J]. *Chinese Journal of Geophysics*, 2024, **67**(2): 452-460 (马彬, 黄玲, 吴晗, 等. 2015 年 3 月特大磁暴期间中国区域电离层 TEC NeuralProphet 预报模型研究 [J]. *地球物理学报*, 2024, **67**(2): 452-460)
- [14] YANG Mo, WANG Jing. A spatial-temporal attention based BiLSTM for stock index prediction[J]. *Operations Research and Management Science*, 2023, **32**(8): 174-180 (杨慕, 王静. 基于时空注意力机制的双向长短期记忆神经网络的股指预测研究 [J]. *运筹与管理*, 2023, **32**(8): 174-180)
- [15] YANG Zixing. Research on Short-Term Wind Power Prediction Based on Hybrid CNN-BiLSTM-AM Model[D]. Beijing: Beijing Jiaotong University, 2023
- [16] ZHANG Zhenchao. Remote Sensing Image Based on Convolutional Neural Network Model Scene Classification Research[D]. Ganzhou: Jiangxi University of Science and Technology, 2022 (张振超. 基于卷积神经网络模型的遥感影像场景分类研究 [D]. 赣州: 江西理工大学, 2022)
- [17] LIU Libo, CHEN Yiding, ZHANG Ruilong, *et al.* Some investigations of ionospheric diurnal variation[J]. *Reviews of Geophysics and Planetary Physics*, 2021, **52**(6): 647-661
- [18] ZHANG Ting, ZHAO Qingxin, ZHONG Huixin, *et al.* Accuracy analysis of IRI 2016 model in ocean and land areas[J]. *Science of Surveying and Mapping*, 2021, **46**(9): 14-33 (张亭, 赵庆鑫, 钟慧鑫, 等. 国际参考电离层 2016 模型在陆海区域的精度分析 [J]. *测绘科学*, 2021, **46**(9): 14-33)
- [19] SONG Rui. Modeling Ionospheric f_0F_2 in China and Its Research on Application[D]. Beijing: Institute of Earthquake Forecasting, China Earthquake Administration, 2018
- [20] GUO Qijia, YAO Yibin, ZHOU Yongjiang. PM2.5 random forest prediction model incorporating GNSS meteorological parameters[J]. *Science of Surveying and Mapping*, 2021, **46**(4): 37-42,56

作者简介



朱佳豪 男, 2000 年生, 河南商丘人, 现为江苏师范大学地理测绘与城乡规划学院电子信息专业硕士研究生。
E-mail: zjh13357771703@126.com



闫文林 (通信作者) 男, 1984 年生, 江苏徐州人, 江苏师范大学地理测绘与城乡规划学院副教授, 主要研究方向为大地测量和卫星导航技术。
E-mail: yanwenlin@jsnu.edu.cn