

基于 LSTM Spatio-temporal Transformer 的电离层 TEC 预测模型

尹 萍¹ 王朝钰^{1,2}

1(中国民航大学电子信息与自动化学院 天津 300300)

2(北京飞机维修工程有限公司 北京 100621)

摘 要 电离层总电子含量 (TEC) 是研究电离层时空变化的重要参数. 本文提出一种结合时空 Transformer (STT) 与长短期记忆网络 (LSTM), 并引入时空注意力机制的电离层 TEC 组合预测模型 (LSTM-STT). 利用 2000–2023 年国际 GNSS 服务欧洲定轨中心 (CODE) 提供的中国及其周边地区的 TEC 数据, 时间范围覆盖 8766 d, 采用滑动窗口方法对数据进行处理, 模型以前 48 h 的 TEC 数据以及辅助参数作为输入, 用于预测后 24 h 的 TEC 数据, 据此构建了 8764 个样本. 为验证模型性能, 分别在 2018 年 (太阳活动低年) 和 2023 年 (太阳活动高年) 开展实验进行预测分析. 研究结果表明, 模型在 2018 年测试集上全部样本的均方根误差 (RMSE) 均值为 1.3981 TECU, 相对精度均值为 90.2524%; 在 2023 年测试集上全部样本的 RMSE 均值为 4.6262 TECU, 相对精度均值为 89.9208%, 说明模型在不同太阳活动状态下均表现出良好的预测性能.

关键词 电离层 TEC, 时空 Transformer, 长短期记忆网络, 预测模型

中图分类号 P352

Ionospheric TEC Prediction Model Based on LSTM Spatio-temporal Transformer

YIN Ping¹ WANG Chaoyu^{1,2}

1(College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300)

2(Aircraft Maintenance & Engineering Corporation, Beijing 100621)

Abstract The ionosphere is a major source of error for satellite navigation, communication, and other applications, and the Total Electron Content (TEC) of the ionosphere is an important parameter for studying the temporal and spatial variations of the ionosphere, and it is extremely important to accurately predict the ionospheric TEC under different space weather conditions. Existing prediction models, when using auxiliary parameters such as solar activity and geomagnetic activity to improve the performance of ionospheric TEC prediction models, treat the auxiliary parameters as global covariates, ignoring the fact that the auxiliary parameters, although having the same value at each location, have differ-

2024-09-12 收到原稿, 2025-03-28 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/>)

ent effects on the ionospheric TEC. To solve this problem, a combined ionospheric TEC prediction model (LSTM-STT) is proposed in this paper, which combines the Space-Time Transformer (STT) with the Long-Short-Term Memory (LSTM) and introduces the space-time attention mechanism. The model adopts the TEC data of China and its surrounding areas from 2000 to 2023 provided by the Center for Orbit Determination in Europe (CODE) of the International GNSS Service organization (IGS), with a time range of 8766 days, and the data are processed by the sliding window method, and the model takes the TEC data of the first 48 hours and the auxiliary parameters as inputs, and the TEC data of the last 24 hours after the prediction are constructed with 8764 samples. A total of 8764 samples were constructed. To verify the performance of the model, experimental prediction analyses were conducted in 2018 (a low solar activity year) and 2023 (a high solar activity year). The results show that the model has an average root mean square error of 1.3981 TECU and an average relative accuracy of 90.2524% on the 2018 test set, and an average root mean square error of 4.6262 TECU and an average relative accuracy of 89.9208% on the 2023 test set, which indicates that the model has good prediction performance.

Key words Ionospheric TEC, Spatio-temporal transformer, LSTM, Prediction model

0 引言

电离层位于地面上方 60~1000 km 高度, 由太阳辐射电离而形成^[1]. 电离层总电子含量 (Total Electron Content, TEC) 的预测对卫星精密定位的误差修正至关重要. 近年来, 电离层 TEC 预测领域有较大进展, 多种预测模型取得良好预测结果. 传统神经网络与信号处理方法的结合是提升预测精度的主要策略之一. 经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD) 与径向基函数 (Radial Basis Function, RBF) 神经网络的结合^[2], 将实验磁暴日均方根误差 (RMSE) 从 4.17 TECU 降低至 3.85 TECU. 奇异谱分析 (Singular Spectrum Analysis, SSA) 与 RBF 神经网络的结合^[3], 显著优于单一 RBF 模型. 经验正交函数分解 (Empirical Orthogonal Function, EOF) 分解与长短期记忆网络 (LSTM) 结合的模式^[4]在云南地区, 实验日 RMSE 最低达到 1.83 TECU, 较单一 LSTM 模型提升了 7%. 多重经验模态分解 (Multi-Ensemble Empirical Mode Decomposition, MEEMD) 神经网络模型^[5]则通过抑制模态混叠, 优化了信号分解. 在模型优化方面, 澳洲野犬优化算法 (Dingo Optimization Algorithm, DOA) 与反向传播 (BP) 神经网络的结合^[6], 模型在实验磁暴日的 RMSE 降低至 3.65 TECU. 同时, 粒子群优化算法 (Particle Swarm Optimization, PSO) 与 Elman 神经网络的结合^[7], 用全局搜索优化初始参数, 提升了收敛速度和预测精度.

在深度学习模型方面, 自相关 Transformer 模型^[8]在预测 24 h 电离层 TEC 的预测任务中, 取得优异表现. 循环神经网络 (Recurrent Neural Network, RNN) 融合太阳风参数等辅助预测参数^[9]也提高了 TEC 预测精度, 另外, ConvLSTM 网络^[10]结合了卷积神经网络和 LSTM 的优势, 能够同时捕捉时空特征, 以 2018 年作为测试集, 全部样本的 RMSE 均值为 1.6799 TECU. 混合 CNN-Bi-LSTM 模型^[11]在不同纬度区域进行了实验, 结果表明, 在 24 h 预测中, 强地磁暴、小中地磁暴和平静期对应的 RMSE 均值分别约为 5.917 TECU, 4.1 TECU 和 3.122 TECU. 此外, LSTM 与国际电离层参考模型 (International Reference Ionosphere, IRI) 相结合的电离层层析 TEC 组合预测方法^[12], 在欧洲区域的实验中, 磁平静日的 RMSE 约为 1.1 TECU. Att-LSTM 模型^[13]通过引入注意力机制, 模型的平均拟合度 (R-Squared) 为 0.9869, 比传统 LSTM 高出 0.0167, 比 RNN 高出 0.1772, 比深度神经网络 (DNN) 高出 0.3467. Transformer 架构在预测精度与计算效率之间取得平衡, 在多步全局 TEC 预测任务中, RMSE 约为 1.8 TECU^[14], 在全球 TEC 地图预测任务中, RMSE 降低至 1.8 TECU. 基于门控循环单元 (Gated Recurrent Unit, GRU) 的 TEC 格点预测模型^[15]结合太阳活动和地磁指数进行预测, 北半球平均相对精度为 83.96%, 南半球为 73.60%, 磁扰动期间平均相对精度比磁平静期高 1.95%. 双向卷积门控循环单元 (Bidirectional Convolutional Gated Recur-

rent Unit, Bi-ConvGRU) 模型^[16]和多模型集成方法^[17](Deep Learning Multi-model Ensemble Method, DLMEM) 的全球 TEC 预测模型通过结合地磁指数、太阳活动指数等辅助参数, 也实现了高精度预测。

基于前期研究成果, 本研究提出一种融合时空注意力机制的 LSTM-STT 组合预测模型, 用于预测电离层 TEC。该模型采用国际 GNSS 服务 (International GNSS Service, IGS) 欧洲定轨中心 (Center for Orbit Determination in Europe, CODE) 的 TEC 数据, 能够综合考虑不同位置辅助参数的重要性, 并根据时间步的动态权重进行调整。进一步, 本文对模型在太阳活动低年 (2018 年) 和太阳活动高年 (2023 年) 的预测性能分别进行分析。

1 模型构建

提出含时空注意力机制的 LSTM-STT 电离层 TEC 组合预测模型, 旨在有效整合主特征 (TEC) 与辅助参数, 提升模型预测精度。模型结构如图 1 所示, 主要包括数据输入模块、时空注意力模块、特征拼接与增强模块、LSTM 模块、Transformer 模块、特征融合层及输出模块。

1.1 数据输入模块

模型的输入由两部分组成: 主特征 (TEC 数据) 和辅助特征 (辅助参数)。主特征数据形状为 $(B, 48, 255)$, 其中 B 表示批处理样本个数, 每个样本包含 48 个时间步, 255 个 TEC 特征 (格网点位置)。辅助特征数据形状为 $(B, 48, f)$, 其中 f 代表辅助参数的数量。

1.2 时空注意力模块

研究区域内各格网点位置辅助参数数值相同, 但是对电离层 TEC 的影响存在显著差异, 模型用前 48 h 的电离层 TEC 和辅助参数预测后 24 h 的电离层 TEC, 且预测过程中不同时间步的权重也不相同。为解决这两个问题, 本研究设计了时空注意力模块, 该模块通过引入可学习的权重矩阵, 在空间和时间维度关系捕捉上更加灵活。

具体而言, 辅助特征形状为 $(B, 48, f)$, 通过空间注意力模块后, 输出形状为 $(B, 48, 255)$, 该过程利用 PyTorch 提供的爱因斯坦求和 (Einstein Summation, einsum) 函数, 通过指定张量索引规则实现矩阵加权映射。此操作确保在每个时间步上对辅助特征进行适当的加权, 从而动态地增强主特征的表达能




图 1 LSTM Spatio-temporal transformer 模型结构

Fig. 1 Structure of the LSTM Spatio-temporal transformer model

确保在每个时间步上对辅助特征进行适当的加权,从而动态增强主特征表达能力. 空间注意力模块权重矩阵形状为 $(48, f, 255)$, 并通过 Xavier 初始化确保初始权重的合理分布.

1.3 特征拼接与增强模块

经过时空注意力加权后的辅助特征与主特征在特征维度上进行拼接, 形成增强后的特征表示 $X_{\text{augmented}}$. 其形状为 $(B, 48, 510)$, 即 255 个主特征与 255 个加权辅助特征拼接, 融合主特征与辅助特征的信息.

1.4 LSTM 模块与 Transformer 模块

LSTM 模块由两层长短期记忆网络组成, 每层包含 512 个隐藏单元. 具体而言, 增强后的特征表示 $X_{\text{augmented}}$ 的输入形状为 $(B, 48, 510)$, 其中 B 为批处理样本个数, 48 为时间步数, 510 为特征维度. 经过第一层 LSTM 处理后, 输出形状为 $(B, 48, 512)$. 随后, 第二层 LSTM 接收第一层的输出, 进一步处理时序信息, 最终输出形状为 $(B, 512)$, 即提取序列中最后一个时间步的隐藏状态.

增强后的特征 $X_{\text{augmented}}$ 也同步输入到 Transformer 模块中. 具体如下: 通过一个线性层将输入特征维度映射到 512. 利用位置编码模块将位置信息注入到输入特征中, 再输入到两层 Transformer 编码器, 每层编码器包含 8 个多头自注意力机制头和前馈神经网络, 经过两层编码器处理后, 输出形状仍为 $(B, 48, 512)$. 从 Transformer 编码器的输出中提取最后一个时间步的表示, 得到形状为 $(B, 512)$ 的向量.

1.5 特征融合层及输出模块

LSTM 模块和 Transformer 模块分别输出形状为 $(B, 512)$ 的特征向量. 模型将这两个特征向量在特征维度上进行拼接, 形成综合特征表示, 其形状为 $(B, 1024)$. 这一拼接操作旨在融合来自 LSTM 的时序依赖信息与来自 Transformer 的长期全局特征信息, 提供更为丰富和全面的特征表示, 随后通过全连接层映射到最终的预测输出.

2 数据与处理

2.1 电离层 TEC 数据和辅助参数

模型的主特征输入参数为电离层 TEC, 辅助参

数包括行星际磁场南向分量 (B_z)、全球地磁扰动等级 K_p 指数、描述磁暴期间环电流变化的 Dst 指数、行星际等效 3 h 幅度指数 (ap)、描述亚暴期间极光电集流变化的 AE 指数、太阳黑子数 (R)、太阳极紫外辐射强度的 $F_{10.7}$ 指数, 以及用于表征日周期信息的正弦项和余弦项 (TS 和 TC) 和季节性信息的正弦项和余弦项 (SS 和 SC). 这些参数在电离层 TEC 预测任务中具有重要作用, 能够有效预示电离层的时空动态特征, 特别是其对地磁活动和太阳活动等外部环境变化的响应.

电离层 TEC 数据来源于国际 GNSS 服务欧洲定轨中心, 覆盖区域为 $70^{\circ}\text{E}-140^{\circ}\text{E}$, $15^{\circ}\text{N}-55^{\circ}\text{N}$, 网格分辨率为经度 5° 和纬度 2.5° . TEC 的单位为 0.1 TECU, 数据时间跨度为 2000 年 1 月 1 日至 2023 年 12 月 31 日. 为确保数据的高时空分辨率, 所有 TEC 数据经过线性插值处理, 确保时间分辨率为 1 h.

其他辅助参数来源于美国国家航空航天局 (NASA) 空间物理数据设施 (Space Physics Data Facility, SPDF) 与 OMNIWeb 数据库, 时间分辨率均整理为 1 h. 在数据预处理阶段, 所有数据均进行了无效值和缺失值的处理, 以确保数据的完整性和一致性. 为保证不同数据源之间的时间同步性, 所有参数时间范围与 TEC 数据保持一致, 为后续模型的训练和预测提供了可靠的基础. 在本研究中, 模型输入为过去 48 h 的 TEC 以及辅助参数数据, 预测输出为未来 24 h 的 TEC 数据.

2.2 数据集划分与样本构建

这里使用的数据集涵盖时间范围为 2000 年 1 月 1 日至 2023 年 12 月 31 日, 共计 8766 d 的数据. 基于这些原始数据, 研究构建了 8764 个样本, 每个样本由两部分组成: 输入部分 (例如 $X_{20231231} \text{.npv}$) 包含目标日期前两天 (2023 年 12 月 29 日和 2023 年 12 月 30 日) 48 h 的 TEC 数据; 输出部分 (例如, $y_{20231231} \text{.npv}$) 记录目标日期 (2023 年 12 月 31 日) 24 h 的 TEC 数据. 此外, 辅助预测参数 (包括 K_p 指数、 R 指数、 Dst 指数、 $F_{10.7}$ 指数、 B_z 磁场分量、 ap 指数、 AE 指数、SS、SC、TS、TC) 以 CSV 文件格式提供, 用于增强模型预测性能.

为了评估模型在不同太阳活动状态下的预测性能, 设计了两项实验任务, 并采用了两种不同的数据划分策略. 第一种划分方案将 2000—2021 年 (共

22 年, 8034 个样本) 作为训练集, 2022 年 (365 个样本) 作为验证集, 2023 年 (365 个样本) 作为测试集. 此划分方案涵盖 2 个太阳活动周期, 适用于评估模型在长期趋势下的泛化能力, 特别关注 2023 年作为太阳活动高年的预测性能. 第二种划分方案采用 2000—2016 年及 2019—2023 年 (共 22 年, 8034 个样本) 作为训练集, 2017 年 (365 个样本) 作为验证集, 2018 年 (365 个样本) 作为测试集, 特别关注 2018 年作为太阳活动低年的预测性能, 以便与 2023 年太阳活动高年进行对比, 分析模型在不同太阳活动年份下的预测表现, 具体划分策略见表 1 和表 2.

2.3 评价指标

研究选取的评价指标是均方根误差 δ_{RMSE} 和平均相对精度 P . 均方根误差的计算公式如下:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\delta_{\text{TEC}, o_i} - \delta_{\text{TEC}, p_i})^2}. \quad (1)$$

平均相对精度 P 的计算公式如下:

$$P = \left[1 - \frac{1}{n} \sum_{i=1}^n \left(\frac{|\delta_{\text{TEC}, o_i} - \delta_{\text{TEC}, p_i}|}{\delta_{\text{TEC}, o_i}} \right) \right] \times 100\%. \quad (2)$$

其中, δ_{TEC, o_i} 表示第 i 个格网点 TEC 的真实值, δ_{TEC, p_i} 表示第 i 个格网点 TEC 的模型预测值.

尽管 δ_{RMSE} 是一种常用的衡量指标, 但其仅考虑预测值与真实值之间的绝对误差. 由于电离层 TEC 在不同时间和不同位置的真实值存在显著差异, δ_{RMSE} 无法充分反映模型在各网格点位置上的预测效能. 因此, 在评估模型预测性能时, 平均相对精度 P 也作为客观性的评价指标之一.

表 1 以太阳活动低年 (2018 年) 作为测试集的划分策略

Table 1 Segmentation strategy with a low solar activity year (2018) as the test set

名称	训练集	验证集	测试集
时间范围	2000—2016年, 2019—2023年	2017年	2018年
样本数量	8034	365	365

表 2 以太阳活动高年 (2023 年) 作为测试集的划分策略

Table 2 Segmentation strategy with a high solar activity year (2023) as the test set

名称	训练集	验证集	测试集
时间范围	2000—2021年	2022年	2023年
样本数量	8034	365	365




图 2 模型在 2018 年测试集上的 RMSE 分布直方图 (a) 和相对精度分布直方图 (b)

Fig. 2 Histogram of RMSE distribution (a) and histogram of average relative accuracy distribution (b) of the model on the test set in 2018




图 3 模型在 2023 年测试集上的 RMSE 分布直方图 (a) 和平均相对精度分布直方图 (b)

Fig. 3 Histogram of RMSE distribution (a) and histogram of average relative accuracy distribution (b) of the model on the test set in 2023




图 4 模型在 2018 年测试集上每天的 RMSE 分布

Fig. 4 Daily RMSE distribution of the model on the test set in 2018




图 5 模型在 2018 年测试集上每天的平均相对精度分布

Fig. 5 Daily average relative accuracy distribution of the model on the test set in 2018

3 结果与讨论

为分析提出的含时空注意力机制的 LSTM-Spatio-Temporal Transformer 电离层 TEC 组合预测模型的预测性能, 模型在测试集上的评价指标包括 RMSE 和平均相对精度 P , 其中 n 为 24×255 , 分别代表连续 24 h 和研究区域上 255 个网格点. 因此, 计算的评价指标是研究区域和研究时间范围上的均值.

3.1 不同太阳活动水平的模型预测性能分析

太阳活动对 TEC 影响显著^[18], 这里将 2018 年 (太阳活动低年) 和 2023 年 (太阳活动高年) 分别作为测试集进行预测分析, 评估模型在不同太阳活动水平下的表现差异. 电离层 TEC 在不同太阳活动年份的半年变化、季节变化及周日变化存在显著差异^[19]. 太阳活动强度不仅显著影响电离层 TEC 数值大小, 还影响其变化特性. 图 2 和图 3 展示了模型在两种数据

划分策略下, 即模型在 2018 年和 2023 年作为测试集全部样本上取得的 RMSE 均值分布和相对精度均值分布.

如图 2 所示, 当 2018 年作为测试集时, 全部样本的 RMSE 数值很小, 均值为 1.3981 TECU, 68.27% 的样本 RMSE 均值分布在 0.9894~1.8068 TECU 内, 表明模型预测较为集中且稳定, 平均相对精度均值高达 90.2524%, 68.27% 的样本平均相对精度分布在 88.2997%~92.2051%, 显示出模型在太阳活动平静时期的高预测精度. 相对而言, 如图 3 所示, 当以 2023 年作为测试集时, RMSE 均值显著增大, 均值为 4.6262 TECU, 68.27% 的样本 RMSE 均值分布在 3.2417~6.0107 TECU, 表明误差值仍然较为集中, 平均相对精度均值略微下降到 89.9208%, 68.27% 的样本平均相对精度均值分布在 86.8440%~92.9976%, 这反映了在太阳活动活跃年份电离层变化的复杂性



图6 模型在2023年测试集上每天的RMSE分布

Fig. 6 Daily RMSE distribution of the model on the test set in 2023

有所增加,但是本文所提模型的预测指标仍然保持相对稳定。

综上所述,模型在太阳活动低年(2018年)预测性能优于太阳活动高年(2023年),这可能归因于太阳活动平静期电离层变化更为规律,使得模型更易捕捉其变化模式,而在太阳活动活跃期,电离层变化剧烈且复杂,增加了预测难度,导致预测误差增大,但是模型在两种太阳活动状态下都取得较高的预测精度,展现出良好的预测性能。

3.2 不同地磁活动条件下模型的预测性能分析

太阳黑子数和电离层TEC存在相关性,太阳活动状态直接影响TEC的变化^[20,21],而地磁活动也对电离层TEC变化有显著影响。本节旨在分别评估模型在太阳活动高年和低年预测性能的同时,评估模型预测性能随地磁活动强度的变化,从而分析地磁活动变化对模型预测性能的影响。

图4和图5分别给出了2018年作为测试集时,每日RMSE均值和每日平均相对精度均值的变化。如前所述,由于2018年是太阳活动低年,模型在测试集上整体表现出较低的RMSE数值。根据地磁活动标准^[22],在地磁平静期($Dst \geq -30$ nT)时,每日RMSE均值大多维持在1~1.5 TECU,平均相对精度均值约为90%;而在地磁暴期($Dst < -30$ nT)时,部分日期误差可达3~4 TECU,但仍然处于合理范围,平均相对精度均值约为88%。基于Dst指数划分标准进一步计算,平静期所有样本RMSE均值为1.3410 TECU,平均相对精度均值为90.4354%;磁暴期所有样本RMSE均值上升至1.8042 TECU,平均相对精度均值降至88.9514%。

图6和图7分别给出了2023年作为测试集时,每日RMSE均值和每日平均相对精度均值的变化。如前所述,由于2023年太阳活动明显增强,模型在测




图 7 模型在 2023 年测试集上每天的平均相对精度分布

Fig. 7 Daily average relative accuracy distribution of the model on the test set in 2023

试集上 RMSE 数值显著增大. 在地磁平静期 ($Dst \geq -30$ nT) 时, 每日 RMSE 均值大多在 3~4 TECU, 平均相对精度均值约为 89%; 地磁暴期 ($Dst < -30$ nT) 时, RMSE 数值增大, 部分日期误差可达 6~8 TECU, 而每日平均相对精度均值大多保持在 87% 左右. 基于 Dst 指数划分标准进一步计算, 平静期所有样本 RMSE 均值为 4.3274 TECU, 平均相对精度均值为 90.5192%; 磁暴期所有样本 RMSE 均值则上升至 5.1928 TECU, 平均相对精度均值下降至 88.7856%.

可以看出, 无论是在 2018 年还是 2023 年, 模型在地磁条件稳定时均能准确捕捉 TEC 变化趋势, 保持较高预测精度. 在持续磁暴期间, 模型 RMSE 值大多数先上升后下降, 平均相对精度则呈现先下降后上升的趋势, 表明模型具备一定对地磁环境变化的调节能力. 综上所述, 太阳活动显著影响地磁活动, 地磁活动对电离层 TEC 产生显著影响, 从而给模型预测性能带来巨大挑战, 但是无论是太阳活动高年还是太阳

活动低年, 地磁扰动期相较于地磁平静期, RMSE 值有所增加, 但模型平均相对精度依然保持在较高水平, 表明该模型在不同太阳活动年份的不同地磁活动状态下均具有良好的适应性.

3.3 模型预测的电离层 TEC 分布评估

为更清晰地显示地磁平静期与地磁暴期的预测结果, 这里分别选择模型在 2018 年和 2023 年特定的日期, 绘制了相应的电离层 TEC 真实值、模型预测值和两者误差值的分布图, 并按 UT 时区显示每天的 4 个时刻. 图 8 和图 9 分别给出了 2018 年和 2023 年各 2 天的对比结果. 在地磁平静期, 2018 年 1 月 28 日 (Dst 最小值为 -9 nT) 和 2023 年 7 月 1 日 (Dst 最小值为 -11 nT) 时, 模型 RMSE 均值分别为 0.8585 TECU 和 2.7664 TECU, 平均相对精度均值分别为 92.26% 和 92.56%. 预测的 TEC 值与实际观测值高度吻合, 误差分布均匀且数值较低, 表明模型在地磁平静条件下具有良好的预测性能. 相比之下, 在地磁暴期, 2018 年 8 月 26 日 (Dst 最小值为




图 8 2018 年 1 月 28 日地磁平静期 (a) 与 8 月 26 日磁暴期 (b) 的 TEC 预测对比

Fig. 8 Comparison of TEC predictions during the geomagnetic quiet period on 28 January (a) and geomagnetic storm period on 26 August (b) 2018




图 9 2023 年 7 月 1 日地磁平静期 (a) 与 11 月 5 日磁暴期 (b) 的 TEC 预测对比

Fig. 9 Comparison of TEC predictions during the geomagnetic quiet period on 1 July (a) and geomagnetic storm period on 5 November (b) 2023

-175 nT, 大磁暴期) 和 2023 年 11 月 5 日 (Dst 最小值为 -163 nT, 大磁暴期) 时, 模型的 RMSE 均值显著上升至 4.0709 TECU 和 7.5744 TECU, 平均相对精度均值分别下降至 80.00% 和 85.49%. 在地磁暴期间, TEC 波动剧烈, 预测值与实际观测值之间的偏差显著增大, 误差主要集中在高纬度和低纬度地区, 表明模型在强地磁扰动条件下预测能力有所下降. 然而, 即使在本节选定大地磁暴条件下, 电离层 TEC 预测精度仍在维持在 85% 左右, 与 GRU 模型^[15] 在北半球磁扰动期平均预测精度均值为 84.56% 接近, 预测误差整体仍集中在一定范围内, 未出现失真, 仍然表现出良好的预测性能.

4 结论

为能够在不同空间天气条件下准确预测电离层 TEC 分布, 提出了一种结合时空 Transformer 和 LSTM 的含时空注意力机制的预测模型. 利用 2000—2023 年国际 GNSS 服务欧洲定轨中心提供的中国及其周边地区的 TEC 数据, 共计 8766 天, 构建了 8764 个样本, 采用滑动窗口方法进行数据处理, 并分别在 2018 年 (太阳活动低年) 和 2023 年 (太阳活动高年) 开展实验进行预测分析. 实验结果显示, 该模型在太阳活动低年 (2018 年) 和太阳活动高年 (2023 年) 的测试集上均表现出较高的预测精度. 具体而言, 在 2018 年测试集上, 全部样本的 RMSE 均值为 1.3981 TECU, 平均相对精度均值达到 90.2524%; 在 2023 年测试集上, 全部样本的 RMSE 均值为 4.6262 TECU, 平均相对精度均值为 89.92%. 同时, 模型在地磁平静期和地磁暴期的预测表现良好, 具体而言, 基于 Dst 指数划分标准^[22], 模型在 2018 年测试集上平静期和磁扰动期的平均相对精度均值分别为 90.4354% 和 88.9514%, 模型在 2023 年测试集上平静期和磁扰动期的平均相对精度均值分别为 90.5192% 和 88.7856%, 相较于 LSTM-DNN 混合模型^[23] 在 24 h 预测任务中取得 82.33% 的平均相对精度都有所改进, 表明模型在不同地磁活动条件下具有较强的适应能力. 未来将致力于研究电离层 TEC 和太阳活动, 地磁活动之间的复杂耦合关系, 继续优化预测模型.

致谢 本研究所使用的电离层 TEC 数据由国际

GNSS 服务 (IGS) 欧洲定轨中心 (CODE) 提供, 数据从 <https://cddis.nasa.gov/archive/gnss/products/ionex> 获取. 行星际和地磁活动相关参数来源于 <https://omniweb.gsfc.nasa.gov/>.

参考文献

- [1] XIONG Nianlu, TANG Cunchen, LI Xingjian. Introduction to Ionospheric Physics[M]. Wuhan: Wuhan University Press, 1999 (熊年禄, 唐存琛, 李行健. 电离层物理概论 [M]. 武汉: 武汉大学出版社, 1999)
- [2] LIU Shuqiong, GAO Xin, LI Changchun. Prediction models of ionospheric TEC by EEMD and radial basis function neural network[J]. *Engineering of Surveying and Mapping*, 2020, **29**(3): 15-19 (刘淑琼, 高鑫, 李长春. EEMD-RBF 神经网络的电离层 TEC 预报模型 [J]. *测绘工程*, 2020, **29**(3): 15-19)
- [3] HU Wenquan. Application of improved model based on RBF neural network in ionospheric TEC prediction[J]. *Geomatics & Spatial Information Technology*, 2023, **46**(8): 164-167 (胡文权. 基于 RBF 神经网络的改进模型在电离层 TEC 预报中的应用 [J]. *测绘与空间地理信息*, 2023, **46**(8): 164-167)
- [4] TANG Jun, LI Yinjian, ZHONG Zhengyu, *et al.* Prediction model of ionospheric TEC by EOF and LSTM neural network[J]. *Journal of Geodesy and Geodynamics*, 2021, **41**(9): 911-915, 944 (汤俊, 李垠健, 钟正宇, 等. EOF-LSTM 神经网络的电离层 TEC 预报模型 [J]. *大地测量与地球动力学*, 2021, **41**(9): 911-915, 944)
- [5] TANG Jun, GAO Xin. Prediction models of Ionospheric TEC by MEEMD and Elman recurrent neural network[J]. *Journal of Geodesy and Geodynamics*, 2020, **40**(4): 395-399 (汤俊, 高鑫. MEEMD-Elman 神经网络的电离层 TEC 预报模型 [J]. *大地测量与地球动力学*, 2020, **40**(4): 395-399)
- [6] NI Yude, YAN Miaoyu, LIU Ruihua. Short-term prediction of ionospheric TEC based on DOA-BP neural network[J]. *Acta Aeronautica et Astronautica Sinica*, 2024, **45**(4): 328707 (倪育德, 闫苗玉, 刘瑞华. 基于 DOA-BP 神经网络的电离层 TEC 短期预测 [J]. *航空学报*, 2024, **45**(4): 328707)
- [7] TANG Jun, ZHONG Zhengyu, DING Mingfei, *et al.* A prediction model of ionospheric TEC in China based on Elman neural network improved by Particle Swarm Optimization algorithm[J/OL]. *Geomatics and Information Science of Wuhan University*, 1-15[2024-12-03]. <http://kns.cnki.net/kcms/detail/42.1676.TN.20230403.1808.005.html> (汤俊, 钟正宇, 丁明飞, 等. 利用粒子群算法改进 Elman 神经网络的中国区域电离层 TEC 预报 [J/OL]. *武汉大学学报 (信息科学版)*, 1-15[2024-12-03]. <http://kns.cnki.net/kcms/detail/42.1676.TN.20230403.1808.005.html>)
- [8] YUAN Yuhuan, XIA Guozhen, ZHANG Xinniao, *et al.* Synthesis-style auto-correlationbased transformer: A learner on

- ionospheric TEC series forecasting[J/OL]. *Space Weather*, 2023, 21, e2023SW003472. <https://doi.org/10.1029/2023SW003472>
- [9] YUAN Tianjiao, CHEN Yanhong, LIU Siqing, *et al.* Prediction model for ionospheric total electron content based on deep learning recurrent neural network[J]. *Chinese Journal of Space Science*, 2018, 38(1): 48-57 (袁天娇, 陈艳红, 刘四清, 等. 基于深度学习递归神经网络的电离层总电子含量经验预报模型[J]. *空间科学学报*, 2018, 38(1): 48-57)
- [10] 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)
- [11] REN X C, ZHAO B Q, REN Z P, *et al.* Deep learning-based prediction of global ionospheric TEC during storm periods: Mixed CNN-BiLSTM method[J]. *Space Weather*, 2024, 22(7): e2024SW003877
- [12] 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)
- [13] 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)
- [14] SHIH C Y, LIN C Y T, LIN S Y, *et al.* Forecasting of global ionosphere maps with multi-day lead time using Transformer-based neural networks[J]. *Space Weather*, 2024, 22(2): e2023SW003579
- [15] YIN Mengting, ZOU Ziming, ZHONG Jia. A prediction model of the grid point ionospheric TEC[J]. *Chinese Journal of Space Science*, 2021, 41(4): 568-579 (殷梦婷, 邹自明, 钟佳. 一种电离层 TEC 格点预测模型[J]. *空间科学学报*, 2021, 41(4): 568-579)
- [16] TANG J, ZHONG Z Y, HU J C, *et al.* Forecasting regional Ionospheric TEC maps over china using BiConvGRU deep learning[J]. *Remote Sensing*, 2023, 15(13): 3405
- [17] 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
- [18] LI Yongtao, LI Jianwen, DAI Taogao, *et al.* Influence of solar activity on ionospheric TEC change[J]. *Chinese Journal of Space Science*, 2018, 38(6): 847-854 (李涌涛, 李建文, 代桃高, 等. 太阳活动对电离层 TEC 变化影响分析[J]. *空间科学学报*, 2018, 38(6): 847-854)
- [19] ZHAO Haishan, YANG Li, XU Shiyi. Analysis of ionospheric TEC variation characteristics in solar activity years[J]. *Journal of Navigation and Positioning*, 2017, 5(1): 24-30 (赵海山, 杨力, 徐世依. 太阳活动高低年电离层 TEC 变化特性分析[J]. *导航定位学报*, 2017, 5(1): 24-30)
- [20] AN Yuzhu, ZHANG Ren, WANG Weimin, *et al.* Correlation analysis between sunspot and TEC[J]. *Journal of PLA University of Science and Technology (Natural Science Edition)*, 2012, 13(5): 571-576 (安玉柱, 张韧, 王伟民, 等. 太阳黑子数与电离层 TEC 的相关性分析[J]. *解放军理工大学学报 (自然科学版)*, 2012, 13(5): 571-576)
- [21] LIU Libo, WAN Weixing, CHEN Yiding, *et al.* Solar activity effects of the ionosphere: A brief review[J]. *Chinese Science Bulletin*, 2011, 56(12): 1202-1211 (刘立波, 万卫星, 陈一定, 等. 电离层与太阳活动性关系[J]. *科学通报*, 2011, 56(7): 477-487. DOI: 10.1007/s11434-010-04226-9)
- [22] China Meteorological Administration. QX/T 239-2014 Levels of geomagnetic activity[S]. Beijing: China Meteorological Press, 2014 (中国气象局. QX/T 239-2014 地磁活动水平分级[S]. 北京: 中国气象出版社, 2014)
- [23] LIAO Wenti, CHEN Zhou, ZHAO Yuxin, *et al.* Short- and medium-term forecasting of global ionospheric TEC map based on hybrid model LSTM-DNN[J]. *Spacecraft Environment Engineering*, 2021, 38(3): 281-286 (廖文梯, 陈洲, 赵瑜馨, 等. 利用混合模型 LSTM-DNN 进行全球电离层 TEC map 的中短期预报[J]. *航天器环境工程*, 2021, 38(3): 281-286)

作者简介



尹萍(通信作者) 女, 1970 年出生于天津市, 现为中国民航大学电子信息与自动化学院副研究员, 博士, 硕士生导师, 主要研究方向为卫星导航技术、电离层/大气层遥感遥测、层析成像与探测等。
E-mail: pyin2001@hotmail.com



王朝钰 男, 1998 年出生于湖北省鄂州市, 硕士研究生, 研究方向为卫星导航技术、电离层遥感遥测成像、深度学习、智能布粮装置。
E-mail: 2512609881@qq.com