

WANG Shuai, QUAN Lin, WANG Kunpeng, LI Ling, YUAN Gang, KANG Lihua. A Multiplicative Model with Frequency-domain Features Superimposed on Time-domain Mutations for Predicting Ionospheric TEC Methods (in Chinese). *Chinese Journal of Space Science*, 2025, 45(6): 1439–1450. CSTR:32142.14.cjss.2024-0123. DOI:10.11728/cjss2025.06.2024-0123

频域特征叠加时域突变的乘性模型 预测电离层 TEC 方法

王 帅^{1,2,3} 全 林¹ 王鲲鹏¹
李 泠¹ 苑 刚¹ 康丽华²

1(北京跟踪与通信技术研究所 北京 100094)

2(航天工程大学航天信息学院 北京 101416)

3(中国地质大学(武汉) 地球物理与空间信息学院 武汉 430074)

摘 要 电离层总电子含量 (TEC) 是电离层的重要特征参数, 对导航误差修正等应用有较大影响, 但是目前的电离层 TEC 预报精度无法完全满足需求, 尤其在太阳风暴期间的精度和提前量方面存在不足. 针对区域电离层 TEC 预报需要, 综合考虑电离层 TEC 的频域和时域特性, 根据电离层 TEC 的变化受太阳活动影响存在趋势性、周期性和突发性的特征, 在分析太阳活动高低年趋势的基础上, 在频域用多个周期长度解析电离层 TEC 变化, 在时域上考虑地磁暴等因素对电离层 TEC 的突发性影响, 将扰动暴时 (*Dst*) 指数、经纬度作为输入参数, 对各个区域磁层-电离层耦合情况进行特异性建模. 实验结果表明, 在地磁平静时期中纬度地区, 本文方法在太阳活动低年 7 天预报值的均方根误差 (RMSE) 优于 1.262 总电子含量单位 (TECU), 1 天预报值的 RMSE 优于 1.094 TECU, 在太阳活动高年 7 天预报值的 RMSE 优于 2.771 TECU. 在地磁活跃时期, 7 天预报值的 RMSE 优于 4.186 TECU, 1 天预报值的 RMSE 优于 4.115 TECU. 本文建立了具备 7 天提前量的预报模型, 方法在预报精度和时效方面表现良好.

关键词 电离层总电子含量, 7 天预测, 频域时域叠加, 地磁扰动

中图分类号 V419

A Multiplicative Model with Frequency-domain Features Superimposed on Time-domain Mutations for Predicting Ionospheric TEC Methods

WANG Shuai^{1,2,3} QUAN Lin¹ WANG Kunpeng¹
LI Ling¹ YUAN Gang¹ KANG Lihua²

1(Beijing Institute of Tracking and Communication Technology, Beijing 100094)

2024-09-30 收到原稿, 2025-04-28 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/>)

2(Space Information College, Space Engineering University, Beijing 101416)

3(School of Geophysics and Geomatics, China University of Geosciences (Wuhan), Wuhan 430074)

Abstract Total Electronic Content (TEC) is an important characteristic parameter of the ionosphere, which has a great influence on the navigation error correction and other applications, but the current ionospheric TEC prediction accuracy cannot fully meet the demand, and there are deficiencies in the accuracy and lead time. The paper focuses on the needs of regional ionospheric TEC forecasting, comprehensively considers the characteristics of ionospheric TEC in both frequency and time domains, analyzes the ionospheric TEC changes in multiple cycle lengths in the frequency domain according to the characteristics of trend, periodicity, and suddenness of the changes in the ionospheric TEC affected by solar activities, considers the suddenness of the geomagnetic storms and other factors on the ionospheric TEC in the time domain, and considers the *Dst* index and latitude/longitude as the input parameters for forecasting. Forecast input parameters, and train the specificity of the magnetosphere-ionosphere coupling in each region. The experimental results show that the Root Mean Square Error (RMSE) of the proposed method is better than 1.262 Total Electronic Content Unit (TECU) in the middle latitude region during the geomagnetic lull period. The RMSE of 1-day forecast value is better than 1.094 TECU, and the RMSE of 7-day forecast value is better than 2.771 TECU during high solar activity years. The RMSE of the 7-day forecast value is better than 4.186 TECU and the RMSE of the 1-day forecast value is better than 4.115 TECU during the geomagnetic active period. In this paper, a prediction model with a 7-day lead is established, and the method shows good performance in forecasting accuracy and timeliness.

Key words Total ionospheric electron content, 7-day forecast, Superposition of frequency domain and time domain, Geomagnetic disturbance

0 引言

电离层是近地空间的等离子体, 会与通过的电磁波相互作用, 从而影响通信、导航、测控等. 电离层 TEC 是电离层的重要物理量, 对电磁波信号在电离层的延迟有直接影响, 需要构建模型进行 TEC 预报, 对延迟造成的误差实时修正. 但是, 电离层活动状态受到太阳、地磁场、大气等条件的复杂影响, 表现出丰富多变的时空特性, 难以通过数值预报的方法进行准确预报. 对 TEC 的预报是空间环境预报的重要内容, 也是重大难题.

电离层 TEC 的预报目前以经验模型方法为主, 即用自回归模型 (AR)、自回归积分滑动平均模型 (ARIMA) 和机器学习等方法, 将电离层视为数据进行统计分析, 从而进行预测. 国际参考电离层 (IRI)、克罗布查 (Klobuchar)、本特 (Bent) 等模型能够描述电离层 TEC 的总体分布规律, 但是在描述区域电离层 TEC 的准确性上有所欠缺, 目前学者研究主要集中在时间序列分析的预报方法上. Yuan 等^[1]利用行

星际太阳风参数、太阳活动指数、地磁活动指数、电离层 TEC 格点化数据, 预测 24 h 单站 TEC, 实验结果表明深度递归神经网络比反向传播神经网络更适用于电离层 TEC 短期预报, 并且在输入因素中加入太阳风数据能够有效改善预报效果. Zhai 等^[2]将时序预测模型应用于电离层 TEC 的异常状态探测, 实验结果表明时序预测模型相对于四分位距 (IQR) 和 ARIMA 在预测准确度上有较大改善. Chen 等^[3]通过对电离层 TEC 数据统计分析得出预报的经验模型, 实验结果表明模型预报数据比 IRI 更接近于实测结果. Tang 等^[4]利用因果卷积和长短时记忆网络 (LSTM), 将太阳在 $F_{10.7}$ 的流量、地磁活动 *Dst* 指数、TEC 数据作为输入使用, 综合多个数据的影响, 在高纬度效果好. Xiong 等^[5]利用反向传播 (BP) 神经网络预测电离层 TEC, 实验结果表明该模型能够很好地描述不同季节电离层 TEC 的周日变化. Huang 和 Yuan^[6]以太阳 $F_{10.7}$ 流量、*Dst*、TEC 等数据作为影响因素, 利用径向基网络模型预报电离层 TEC, 最终误差在 5 TECU 以下. Tang 和 Gao^[7]建

立贝叶斯正则化埃尔曼 (Elman) 回归神经网络模型, 改进了 BP 神经网络的预报效果. Wen 等^[8] 利用 LSTM 模型构建了中纬度地区电离层 TEC 预测模型, 实验结果证明该结果在磁暴条件下预测结果优于 BP 模型和 IRI 模型. LSTM 神经网络已在 TEC 预测方面取得了较多成果^[9-12]. Liu 等^[13] 用 db4 小波分解改进 ARIMA, 在电离层非平稳状态时能够有效控制预报的最大误差. 上述方法都将电离层 TEC 视为时序数据序列, 并且通过时间相关的预测分析方法对电离层 TEC 进行分析预报. Song 等^[14] 针对中国区域特征提出了一种基于遗传算法的神经网络 (GA-NN) 预测模型. 深度学习被认为是第二代神经网络的一个功能, 可以用于更好地模拟电离层 TEC 的时空变化^[15], Chen 等^[16] 提出了一种改进的深度学习算法来预测 TEC 地图, 在不同时间和不同地磁条件下显示了令人满意的电离层峰值结构. 这些研究在数据层面, 将 TEC 看作受空间天气影响的时序数据, 在短期时序变化方面上开展了很多有益的工作, 但是综合考虑 TEC 长期变化特征和短期时序变化的方法研究较少. 如果用短期数据无法考虑逐年的周期性, 如果用长期数据则无法兼顾多年之间的趋势性.

电离层状态受到太阳活动和地磁活动的影响^[17], 会随着逐年太阳活动的高低呈现出趋势性; 与此同时, 受到一年四季、每天东升西落的太阳活动影响, 电离层也呈现了逐年和逐日的周期性; 电离层也会受到突发的太阳风暴影响造成局部 TEC 突变性. 上述这些因素都表明, 电离层 TEC 在时间上是一个由趋势、周期和部分突变值构成的复杂数据序列, 需要对数据构成的各个要素进行分解分析^[18,19].

本文综合 TEC 的长期频域特征和短期时域特征进行电离层 TEC 的分析预报, 分析电离层 TEC 的数据特征, 提出电离层 TEC 变化的内在因素规律, 建立描述其内在变化特征的对应数学模型, 针对突发地磁活动情况下的 TEC 变化, 在时域上对暴时 TEC 设计对应响应模型实现对频域结果的修正, 设计实验对提出的算法结果进行验证.

1 方法

1.1 数据特征分析

电离层中的电子产生主要靠地球高层大气的分

子和原子在太阳的紫外线、X 射线和高能粒子的作用下电离产生自由电子, 电子消失主要依靠电子的漂移和电子与正离子的复合作用, 区域内的电离层 TEC 取决于该区域的电子产生速率和电子消失速率之差的积分. 电离层电子的产生与太阳活动密切相关. 太阳活动强度的趋势性会造成电离层 TEC 活动的趋势性. 太阳存在约 11 年的活动周期性, 在太阳活动周的上升期, 电离层 TEC 的变化剧烈程度呈现上升的趋势; 在太阳活动周的下降期, 电离层 TEC 的变化剧烈程度呈现下降趋势; 除了 11 年的太阳活动周之外, 太阳强度还存在每年地球绕太阳公转导致的逐年太阳活动周期性, 以及地球自转导致的逐日太阳活动周期性, 这些会导致电离层 TEC 存在逐年和逐日的周期性. 同时, 由于太阳风暴爆发对电离层 TEC 有很大影响, 太阳风暴的突变性还会导致电离层 TEC 的变化存在突变性. 综上, TEC 的变化主要由三部分构成: 趋势因素, 例如太阳活动高年、低年; 周期因素, 例如太阳的逐年逐日变化; 突变因素, 例如太阳活动突发的太阳风暴等.

电离层 TEC 的趋势性和周期性特征较明显, 但是突变性特征的规律分析存在较大困难. 自然因素对电离层扰动中, 太阳突发活动引起的地磁暴是最主要因素. 因机理不同, 磁暴对不同纬度的电离层 TEC 影响特征也不相同, 造成了不同地区对磁暴的响应在时间和强度上的差异. 电离层显著响应太阳和磁层的能量输入变化, 对于太阳活动的突发性变化如地磁暴对电离层 TEC 影响发生快并且持续时间短, 现有数据量和数据分辨率难以从频率分析, 因此考虑从时域对地磁暴与电离层 TEC 影响进行分析.

太阳活动对地球电离层的影响, 首先由行星际对流电场作用于磁层, 通过磁层-电离层激励使环电流增加, 由于地磁与电离层的耦合关系对电离层扰动. 磁暴期间, 磁层极区注入到电离层/热层系统的能量、动量和物质在很短的时段内急剧增加, 极区电离层电场强度和极光高能粒子沉降显著增强, 增强的极区电离层电场和电流导致的极区电离层/热层系统的焦耳加热增强, 增强的高能粒子沉降会增强 E 层电离层电离、增大电导率, 显著放大焦耳加热. 增强的焦耳加热会明显影响热层的成分和密度, 减小氧氮比. 增强的电场驱动了等离子体对流的增强, 等离子体对流会拖曳中性大气, 进而增强了极区热层中性风场. 增强

的焦耳加热也会严重地影响极区的水平中性压力梯度, 改变热层中性风场. 增强的极区热层风场把极区的高密度大气带到中低纬, 形成了全球尺度的热层暴, 随着热层状态的改变, 全球电离层也发生了剧烈的变化, 形成了全球尺度的电离层暴. 主相期间电离层电子密度通常低于之前的平均值, 形成电离层负暴, 但有时也会高于之前平均值, 形成电离层正暴^[20]. 极区扰动的能量注入对电离层的扰动是从高纬度极区先发生, 逐步向赤道区域扩展. Dst 是中低纬台站测量的地磁场水平分量 H 的每小时平均偏离值, 可以很好地表征地磁活动状态. 由于地磁场与电离层 TEC 之间的耦合关系, Dst 与 TEC 之间存在显著的相关关系. 此外, 电离层 TEC 还受到太阳 X 射线耀斑和太阳质子事件的影响, 但是 X 射线爆发 8 min 后电离层即做出反应, 太阳质子事件主要影响极区电离层, 且时间延迟也仅约为数十分钟, 预报提前量十分有限, 可以近似认为是瞬发事件难以预报.

分析物理机制可知, 地磁暴对 TEC 的影响有以下几个特征.

(1) 地磁变化是电离层 TEC 突变的主要诱因之一, 地磁暴会引起电离层 TEC 的变化, 并且地磁暴先发生, 而后电离层以正暴或负暴的形式响应, 地磁变化和 TEC 变化在时间上有先后顺利.

(2) 地磁暴主相持续时间短约 2 h, 并且可以用 Dst 极值判断主相与恢复相之间的位置, 主相可用作电离层在恢复相期间的先兆, 恢复相最长持续约 7 天.

(3) 地磁暴对中纬度电离层 TEC 的影响主要通过增加和降低等离子体复合率实现, 仍然与区域电离层中性成分和等离子体复合率相关, 可以认为地磁暴对 TEC 的影响对于平稳状态下 TEC 的系统变化来说是一个乘性增益.

(4) 不同地区由于经纬度不同, 对应区域内 TEC 对地磁暴的响应特性也存在时间和特征上的差异, 需要分区域建立 TEC 对 Dst 的响应模型.

(5) 在不同磁暴等级, Dst 和 TEC 的相关关系存在较大差别.

综上, 地磁暴对 TEC 的影响在时间上具备强关联和因果关系, 可以以地磁的 Dst 指数作为电离层 TEC 的输入, Dst 指数可以用 L1 点卫星数据预测得到, L1 点监测到太阳风剧烈变化数据到磁暴发生仍

有 1 h 以上提前量. 模型需先由 L1 点数据实时预测磁暴等级和主相发生时间, 用预测后的 Dst 得到不同磁暴等级, 然后用乘性增益模型实现暴时 TEC 预测.

1.2 电离层 TEC 频域时域叠加模型

运用时间序列分解方法把时间序列 y_t 分成几个部分, 分别是趋势因素 T_t 、周期因素 S_t 、突变因素 U_t 和误差项 ε_t , 即

$$y_t = (T_t + S_t) \times U_t + \varepsilon_t. \quad (1)$$

趋势因素. 趋势项主要用于描述数据随时间变化而呈现的非周期性总体趋势, 可以利用逻辑回归函数实现对潜在变化趋势的拟合.

周期因素. 周期项主要用于描述数据中受到的周期性因素影响而发生的变化. 时间序列数据通常随着时间的变化表现出一定的周期变化, 时间序列数据可能由多个周期的数据共同影响构成, 即随着天、年等变化而呈现出数据的周期性变化. 将周期变化因素用傅里叶模型表示, 通过正弦和余弦函数来表示周期性因素对数据的影响.

突发因素. 突发项也是主要用于描述数据中突发因素引起的变化. 非周期因素对数据变化造成的影响可以看成相互独立可叠加的乘性模型, 并且可以为不同的突发项设置不同的前后窗口值, 表示该突发项会影响前后一段时间的时间序列.

收集第 24 太阳活动周 Dst 数据及地磁暴事件列表, 采用移动平均和低通滤波方法对 Dst 数据进行平滑滤波处理, 去除数据噪声和瞬间现象对地磁状态分析的影响, 根据 Dst 指数对地磁活动情况初步分类, 并收集对应时间范围的 TEC 数据. 因每个位置的电离层在频域和时域变化不尽相同, 需要根据所关注的位置经纬度选择对应位置的历史数据建模. 对 Dst 数据及地磁暴主相发生前 2 h 和发生后 48 h 对 TEC 的影响情况进行分析建模, 方法是以前后 7 天地磁平静时期的 TEC 作为参考, 提取出不同地磁情况对 TEC 的量化影响, 用于将来 Dst 指数达到对应磁暴等级时对平稳状态下 TEC 预测结果进行修正, 形成乘性修正模型, 实现对各个区域的特异性建模. 在预报过程中, 实时采集 Dst 数据序列, 若 Dst 指数在 -30 nT 以上时, 则直接输出频域预测值作为预报结果, 若 Dst 指数小于 -30 nT 并呈现持续下降趋势, 则认为有地磁暴发生并处于主相上升期, 利用模型中

增益对应主相前 2 h 乘性参数进行修正, 若 Dst 出现极值点, 则认为地磁暴由主相转至恢复相, 根据主相等级用建模得到的主相后 48 h 增益系数修正频域预测结果, 作为最终预报输出.

模型运用于电离层 TEC 预测, 主要的优点是无需复杂的特征集构建过程, 模型可解释性好, 多周期性特征描述好.

2 实验过程与结果

实验采用国际全球导航卫星系统服务 (IGS) 提供的电离层相关 TEC 网格数据, 包括最终分析数据和预报数据. 最终分析数据由中国科学院等机构在完成数据收集 11 天后精细分析得到, 精度较高, 可用作评价模型的基准数据; 预报数据在数据获取后快速分析得到, 预测 1 天后 TEC 数据, 时效性较好, 与本文方法应用背景一致, 可用作与本文预测结果对比. 此外, 还使用 LSTM^[21]、IRI 2016 等常用预测方法的结果进行横向对比. 评价指标包括相关系数 ρ 、均方根误差 RMSE (e_{RMSE})、平均绝对误差 MAE (e_{MAE})、决定系数 R^2 , 具体公式如下:

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

$$e_{\text{MAE}} = \frac{1}{n} \left(\sum_{i=1}^n |y_i - \hat{y}_i| \right), \quad (3)$$

$$\rho = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}}, \quad (4)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (5)$$

其中, $\hat{y}$ 为预测值, y 为观测值, $\bar{\hat{y}}$ 和 $\bar{y}$ 分别为所有预测值和观测值的平均值.

2.1 地磁平静时期

对地磁活动平静时期, 即 $Dst \geq -30$ nT 时, 分析算法的预报准确率. 分别选取武汉、上海、北京、广州四个地区的 TEC 数据分析, 分为太阳活动低年冬季和太阳活动高年夏季两种情况.

2.1.1 太阳活动低年地磁平静时期的 7 天预测

以 2014 年 1 月 1 日至 2019 年 1 月 6 日的 TEC 数据作为训练集, 以 2019 年 1 月 7 日至 2019 年 1 月 13 日共 7 天的数据作为测试集, 上述 7 天的 Dst 指数均大于 -30 nT, 地磁活动以平静为主, 极少时间处于微扰程度, 可以视为地磁活动平静时期. 对 2019 年 1 月 7 日 00:00 UT 开始后 7 天的 TEC 变化进行预测, 得到的预测结果与实际结果如图 1 所示. 对多种算法的预测进行量化评价, 结果列于表 1.

2.1.2 太阳活动低年地磁平静时期的 1 天预测

在 2019 年 1 月 7—13 日数据中, 9 日及前后 1 天地磁活动最为平静, 因此选取 2019 年 1 月 9 日作为预测目标日期. 以 2014 年 1 月 1 日至 2019 年 1 月 8 日的 TEC 数据作为训练集, 以 2019 年 1 月 9 日的数据作为测试集. 使用本文算法对 2019 年 1 月 9 日 00:00 UT 开始后 1 天的 TEC 变化进行预测, 得到的预测结果与实际结果如图 2 所示. 对多种算法的预测进行量化评价, 结果列于表 2.

2.1.3 太阳活动高年地磁平静时期的 7 天预测

以 2020 年 1 月 1 日至 2023 年 8 月 20 日的 TEC 数据作为训练集, 以 2023 年 8 月 21—27 日共 7 天的数据作为测试集, 上述 7 天的 Dst 指数均大于 -30 nT, 地磁活动以平静为主, 极少时间处于微扰程度, 可以视为地磁活动平静时期. 在 2023 年 8 月的 $F_{10.7}$ 月平均流量为 183, 是太阳活动高年. 对 2023 年 8 月 21 日 00:00 UT 开始后 7 天的 TEC 变化进行预测, 得到的预测结果与实际结果如图 3 所示. 对多种算法的预测进行量化评价, 结果列于表 3.

2.2 地磁活跃时期

对地磁活动活跃时期, 即 $Dst \leq -30$ nT 时, 分析算法的预报准确率. 分别选取武汉、上海、北京、广州四个地区的 TEC 数据分析.

2.2.1 地磁活跃时期的 7 天预测

以 2014 年 1 月 1 日至 2016 年 1 月 18 日的 TEC 数据作为训练集, 以 2016 年 1 月 20—26 日共 7 天的数据作为测试集, 上述 7 天的 Dst 指数如图 4 所示, 这 7 天中共出现了一次中等磁暴, 其余为平静至小磁暴. 使用本文算法对 2016 年 1 月 20 日 00:00 UT 开始后 7 天的 TEC 变化进行预测, 得到的预测结果与实际结果如图 5 所示. 对多种算法的预测进行量化评价, 结果列于表 4.




图 1 地磁平静期间得到的 7 天预测值与真实值

Fig. 1 7-day forecast values and the actual values during the geomagnetic quiet period

表 1 对武汉等 4 地 TEC 的各种预测方法结果对比

Table 1 Comparison of various prediction methods for TEC in Wuhan, Shanghai, Beijing and Guangzhou regions

地区	方法	ρ	RMSE/TECU	MAE/TECU	R^2
武汉	本文算法	0.971	0.942	0.711	0.926
	LSTM	0.843	1.936	1.458	0.724
	IRI 2016	0.899	3.074	2.610	0.207
	IGS预测	0.957	1.341	1.027	0.849
上海	本文算法	0.973	0.907	0.699	0.932
	LSTM	0.710	2.906	1.999	0.302
	IRI 2016	0.891	3.224	2.739	0.141
	IGS预测	0.961	1.291	1.019	0.862
北京	本文算法	0.949	1.058	0.788	0.871
	LSTM	0.968	1.243	1.082	0.820
	IRI 2016	0.673	2.380	1.891	0.343
	IGS预测	0.964	0.999	0.800	0.884
广州	本文算法	0.958	1.262	0.945	0.915
	LSTM	0.919	2.801	2.331	0.578
	IRI 2016	0.922	4.545	4.101	0
	IGS预测	0.957	1.586	1.215	0.865




图 2 地磁活跃期间得到的预测值与真实值

Fig. 2 Forecast values and the actual values during the geomagnetic activity period

表 2 对武汉等 4 地 TEC 的各种预测方法结果对比

Table 2 Comparison of various prediction methods for TEC in Wuhan, Shanghai, Beijing and Guangzhou regions

地区	方法	ρ	RMSE/TECU	MAE/TECU	R^2
武汉	本文算法	0.992	0.560	0.434	0.973
	LSTM	0.758	2.096	1.724	0.419
	IRI 2016	0.904	3.002	2.433	0.274
	IGS预测	0.988	1.006	0.871	0.918
上海	本文算法	0.992	0.638	0.504	0.969
	LSTM	0.906	1.717	1.266	0.618
	IRI 2016	0.901	3.048	2.512	0.283
	IGS预测	0.988	1.074	0.942	0.911
北京	本文算法	0.948	1.094	0.825	0.846
	LSTM	0.876	2.278	1.862	0.370
	IRI 2016	0.641	2.393	1.975	0.263
	IGS预测	0.980	1.011	0.888	0.868
广州	本文算法	0.990	0.721	0.588	0.972
	LSTM	0.895	3.106	2.349	0.174
	IRI 2016	0.963	4.149	3.796	0.057
	IGS预测	0.992	1.029	0.863	0.941




图 3 地磁平静期间得到的 7 天预测值与真实值

Fig. 3 7-day forecast values and the actual values during the geomagnetic quiet period

表 3 对武汉、上海、北京、广州四个地区 TEC 的各种预测方法结果对比

Table 3 Comparison of various prediction methods for TEC in Wuhan, Shanghai, Beijing and Guangzhou regions

地区	方法	ρ	RMSE/TECU	MAE/TECU	R^2
武汉	本文算法	0.988	1.822	1.442	0.981
	LSTM	0.899	5.466	3.803	0.779
	IRI 2016	0.968	3.103	2.502	0.929
	IGS预测	0.984	2.145	1.690	0.966
上海	本文算法	0.988	1.744	1.395	0.983
	LSTM	0.808	7.603	5.458	0.558
	IRI 2016	0.966	3.187	2.584	0.922
	IGS预测	0.983	2.181	1.643	0.964
北京	本文算法	0.982	2.636	1.957	0.964
	LSTM	0.837	9.957	6.761	0.434
	IRI 2016	0.964	4.335	3.673	0.893
	IGS预测	0.980	2.904	1.951	0.952
广州	本文算法	0.980	2.771	2.208	0.951
	LSTM	0.913	7.718	6.972	0.660
	IRI 2016	0.849	7.916	5.823	0.582
	IGS预测	0.971	3.128	2.324	0.935

2.2.2 地磁活跃时期的一天预测

这里分别选取武汉、上海、北京、广州四个地区的 TEC 数据分析. 以 2014 年 1 月 1 日至 2016 年 1 月 20 日的 TEC 数据作为训练集, 以 2016 年 1 月 21 日的数据作为测试集, 21 日当天 Dst 指数最小为 -92 nT, 属于较强的中等地磁暴. 使用本文算法对 2016 年 1 月 21 日 00:00 UT 开始后 1 天的 TEC 变

化进行预测, 得到的预测结果与实际结果如图 6 所示. 对多种算法的预测进行量化评价, 结果列于表 5.

根据实验结果可知, 本文算法应用于电离层 TEC 预报具有较好的预报精度. 从可视化图像分析来看, 本文算法对 7 天预测效果在地磁平静和活跃期间的趋势均与电离层 TEC 的实测值一致性较好, 对 1 天预测效果在地磁平静和活跃期间的曲线也有相互




图 4 2016 年 1 月 20—26 日连续 7 天的 Dst 指数

Fig. 4 Dst for 7 consecutive days from 20 to 26 January 2016




图 5 地磁活跃期间得到的 7 天预测值与真实值

Fig. 5 7-day forecast values and the actual values during the geomagnetic active period

表 4 对武汉、上海、北京、广州四个地区 TEC 的各种预测方法结果对比
Table 4 Comparison of various prediction methods for TEC in Wuhan, Shanghai, Beijing and Guangzhou regions

地区	方法	ρ	RMSE/TECU	MAE/TECU	R^2
武汉	本文算法	0.923	2.944	2.216	0.804
	LSTM	0.793	4.816	3.921	0.473
	IRI 2016	0.785	6.293	5.181	0.101
	IGS预测	0.835	4.092	2.961	0.620
上海	本文算法	0.941	3.183	2.425	0.751
	LSTM	0.673	5.612	4.221	0.113
	IRI 2016	0.798	6.393	5.396	0
	IGS预测	0.838	3.982	2.895	0.611
北京	本文算法	0.879	3.700	2.924	0.491
	LSTM	0.820	4.773	3.852	0
	IRI 2016	0.721	4.690	3.644	0.182
	IGS预测	0.884	2.531	1.863	0.761
广州	本文算法	0.912	4.186	3.448	0.751
	LSTM	0.529	16.553	14.937	0
	IRI 2016	0.835	8.043	6.772	0.078
	IGS预测	0.884	2.530	1.863	0.884




图 6 地磁活跃期间得到的预测值与真实值
Fig. 6 Forecast values and the actual values during the geomagnetic active period

表 5 对武汉、上海、北京、广州四个地区 TEC 的各种预测方法结果对比
Table 5 Comparison of various prediction methods for TEC in Wuhan, Shanghai, Beijing and Guangzhou regions

地区	方法	ρ	RMSE/TECU	MAE/TECU	R^2
武汉	本文算法	0.966	1.911	1.610	0.832
	LSTM	0.034	9.125	6.970	0
	IRI 2016	0.887	6.761	5.533	0
	IGS预测	0.966	5.408	4.538	0
上海	本文算法	0.962	1.861	1.507	0.866
	LSTM	0.134	5.215	4.231	0.153
	IRI 2016	0.899	6.768	5.413	0
	IGS预测	0.945	5.337	4.592	0
北京	本文算法	0.878	3.091	2.292	0.554
	LSTM	0.413	7.553	6.023	0
	IRI 2016	0.688	4.926	4.038	0
	IGS预测	0.981	2.256	1.850	0.762
广州	本文算法	0.975	4.115	3.506	0.583
	LSTM	0.527	15.184	13.535	0
	IRI 2016	0.957	8.480	7.354	0
	IGS预测	0.980	2.255	1.85	0.762

重叠,表明预测值与基准值吻合较好.从量化数据表格来看,在地磁平静时期,太阳活动低年,7天预报值的 RMSE 优于 1.262 TECU, MAE 优于 0.945 TECU; 1天预报值的 RMSE 优于 1.094 TECU, MAE 优于 0.825 TECU; 太阳活动高年,7天预报值的 RMSE 优于 2.771 TECU, MAE 优于 2.216 TECU. 在地磁活跃时期,7天预报值的 RMSE 优于 4.186 TECU, MAE 优于 3.448 TECU; 1天预报值的 RMSE 优于 4.115 TECU, MAE 优于 3.506 TECU. 对比于其他几种 TEC 预测方法, LSTM 算法对 TEC 的周期特征提取效果也不好,导致 7天预测结果误差较大,仅适用于短期时域预测,且训练时间较长,时效性欠佳; IRI 2016 模型仅能表现出电离层的统计信息; IGS 预测预报效果相对较好,但是综合来看本文算法在各个方面均对以上算法表现出一定优势,可适用于对电离层 TEC 的 7天预报.

3 结论

使用频域与时域相结合的算法对电离层 TEC 进

行预报,针对太阳活动下降期和上升期的中纬度电离层预报进行了实验验证,结果证明能够实现 7天提前量的小时分辨率预报,并且在中等磁暴期间也能很好地预测磁暴对 TEC 的影响.在运用本文算法进行预测的过程中,因为涉及太阳活动周的年趋势,历史数据应当不跨过太阳活动周的峰值年或者是低谷年,以免算法对趋势项发生误判.例如,对第 24 太阳活动周 TEC 特征进行频域分析时,该太阳活动周是 2008 年开始,2020 年结束,在 2014 年达到高年,因此在对 2014 年之后的数据预测时,历史数据导入不宜跨过 2014 年,这是历史数据仅跨越一个太阳活动周,算法无法解析太阳活动的 11 年周期性而导致的.并且由于地磁活动事件数据有限,本文算法对地磁活跃期间的预测能力因训练样本限制以及地磁情况的不断变化和电离层与地磁活动耦合的复杂性,对地磁活跃期间的预测准确性还有待进一步提高.

参考文献

[1] 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)
- [2] ZHAI Dulin, ZHANG Xuemin, XIONG Pan, *et al.* Detection of ionospheric TEC anomalies based on Prophet Time-series Forecasting Model[J]. *Earthquake*, 2019, **39**(2): 46-62 (翟笃林, 张学民, 熊攀, 等. Prophet 时序预测模型在电离层 TEC 异常探测中的应用 [J]. *地震*, 2019, **39**(2): 46-62)
- [3] CHEN Yanhong, WAN Weixing, LIU Libo, *et al.* A statistical tec model based on the observation at Wuhan ionospheric observatory[J]. *Earthquake*, 2002, **22**(1): 27-35 (陈艳红, 万卫星, 刘立波, 等. 武汉地区电离层电子浓度总含量的统计经验模式研究 [J]. *空间科学学报*, 2002, **22**(1): 27-35)
- [4] 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)
- [5] 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 of 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)
- [6] HUANG Z, YUAN H. Ionospheric single-station TEC short-term forecast using RBF neural network[J]. *Radio Science*, 2014, **49**(4): 283-292
- [7] TANG Jun, GAO Xin. Prediction models of ionospheric TEC by Elman neural network with Bayesian regularization[J]. *Journal of Geodesy and Geodynamics*, 2020, **40**(8): 799-805 (汤俊, 高鑫. 贝叶斯正则化的 Elman 神经网络电离层 TEC 预报模型 [J]. *大地测量与地球动力学*, 2020, **40**(8): 799-805)
- [8] WEN Z C, LI S H, LI L H, *et al.* Ionospheric TEC prediction using Long Short-Term Memory deep learning network[J]. *Astrophysics and Space Science*, 2021, **366**(1): 3
- [9] RUWALI A, KUMAR A J S, PRAKASH K B, *et al.* Implementation of hybrid deep learning model (LSTM-CNN) for ionospheric TEC forecasting using GPS data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, **18**(6): 1004-1008
- [10] SRIVANI I, PRASAD G S V, RATNAM D V. A deep learning-based approach to forecast ionospheric delays for GPS signals[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, **16**(8): 1180-1184
- [11] Shaikh M M, Butt R A, Khawaja A. Forecasting Total Electron Content (TEC) using CEEMDAN LSTM model [J]. *Advances in Space Research*, 2023, **71**(10): 4361-4373
- [12] KASELIMI M, VOULODIMOS A, DOULAMIS N, *et al.* A causal long short-term memory sequence to sequence model for TEC prediction using GNSS observations[J]. *Remote Sensing*, 2020, **12**(9): 1354
- [13] 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)
- [14] SONG R, ZHANG X M, ZHOU C, *et al.* Predicting TEC in China based on the neural networks optimized by genetic algorithm[J]. *Advances in Space Research*, 2018, **62**(4): 745-759
- [15] PEREZ R O. Using tensor flow-based neural network to estimate GNSS single frequency ionospheric delay (IONONet)[J]. *Advances in Space Research*, 2019, **63**(5): 1607-1618
- [16] CHEN Z, JIN M W, DENG Y, *et al.* Improvement of a deep learning algorithm for total electron content maps: Image completion[J]. *Journal of Geophysical Research: Space Physics*, 2019, **124**(1): 790-800
- [17] LIAO Zhanguai, WU Beiping, SHEN Xinglin, *et al.* Analysis of ionospheric VTEC temporal-spatial characteristics in Guangxi and surrounding[J]. *Science of Surveying and Mapping*, 2018, **43**(9): 40-45, 62 (廖章回, 吴北平, 申兴林, 等. 广西及周边地区电离层时空特性分析 [J]. *测绘科学*, 2018, **43**(9): 40-45, 62)
- [18] JI Changdong, WANG Qiang, WANG Guipeng, *et al.* TEC prediction of ionosphere based on deep learning LSTM model[J]. *Journal of Navigation and Positioning*, 2019, **7**(3): 76-81 (吉长东, 王强, 王贵朋, 等. 深度学习 LSTM 模型的电离层总电子含量预报 [J]. *导航定位学报*, 2019, **7**(3): 76-81)
- [19] TAYLOR S J, LETHAM B. Forecasting at scale[J]. *The American Statistician*, 2018, **72**(1): 37-45
- [20] QUAN Lin, XUE Junchen, HU Xiaogong, *et al.* Performance of GPS single frequency standard point positioning in China during the main phase of different classified geomagnetic storms[J]. *Chinese Journal of Geophysics*, 2021, **64**(9): 3030-3047 (全林, 薛军琛, 胡小工, 等. 中国区域 GPS 单频点定位在不同类型磁暴主相期间定位性能分析 [J]. *地球物理学报*, 2021, **64**(9): 3030-3047)
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, **9**(8): 1735-1780

作者简介



王帅男, 1991 年出生于湖北省襄阳市, 现为航天工程大学航天信息学院讲师, 主要研究方向为电离层探测与分析预报、空间环境探测设备设计等。
E-mail: mage1120@foxmail.com

全林 (通信作者) 男, 1975 年出生于湖北省仙桃市, 现为北京跟踪与通信技术研究所研究员, 主要研究方向为空间环境监测体系设计、航天器辐射效应及防护等。
E-mail: jlxs@163.com