

OU Ming, GUO Yaping, WANG Fen, WANG Haining, HAN Chao, ZHU Qinglin, ZHEN Weimin. Short-term Forecasting Method of f_0F_2 in the Ionosphere over China Based on Deep Learning (in Chinese). *Chinese Journal of Space Science*, 2026, **46**(3): 639–649. CSTR:32142.14.cjss.2025-0073. DOI:10.11728/cjss2026.03.2025-0073

基于深度学习的中国区域电离层 f_0F_2 短期预报方法*

欧 明¹ 郭雅苹^{2,3} 王 芬³ 王海宁^{3,4}
韩 超² 朱庆林³ 甄卫民³

1(山东科技大学海洋科学与工程学院 青岛 266590)

2(山东科技大学电子信息工程学院 青岛 266590)

3(中国电波传播研究所 青岛 266107)

4(西北工业大学自动化学院 西安 710129)

摘 要 提出一种基于深度学习的电离层 f_0F_2 短期预报方法, 通过采用注意力机制的双向长短期记忆网络 (Bidirectional Long Short-Term Memory Model With Attention Mechanism, BiLSTM-Attention) 算法, 结合前 7 天垂测站电离层 f_0F_2 观测值、世界时、太阳活动指数及地磁活动指数作为输入, 实现了中国区域电离层 f_0F_2 的预报. 模型对比分析结果表明: 低纬度台站的预报误差显著高于中纬度台站, BiLSTM-Attention 模型表现最优, 长短期记忆网络 (LSTM) 模型次之, 与国际参考电离层模型 (IRI) 相比, BiLSTM-Attention 模型的均方根误差 (RMSE) 降低了 44.2%, 平均绝对误差 (MAE) 降低 47%, 而决定系数 (R^2) 提升 21.3%; 磁暴期间, BiLSTM-Attention 模型成功捕捉中国区域电离层负暴效应 (f_0F_2 下降), 与观测值非常一致, 而 IRI 模型开启暴时模式后, f_0F_2 预测值与实际观测值之间依然存在一定偏差; 随着预报时间从 1 h 增加至 24 h, 模型预报误差呈系统性上升趋势, RMSE 从 0.99 MHz 增至 2.05 MHz, MAE 从 0.69 MHz 升至 1.57 MHz, R^2 则由 0.93 减至 0.75. 相关研究为空间天气预警及短波通信系统优化提供了高精度电离层参数的预报支撑.

关键词 电离层, F_2 层临界频率 (f_0F_2), 注意力机制的双向长短期记忆网络, 深度学习, 短期预报
中图分类号 P352

Short-term Forecasting Method of f_0F_2 in the Ionosphere over China Based on Deep Learning

OU Ming¹ GUO Yaping^{2,3} WANG Fen³ WANG Haining^{3,4}

* 国家重点研发计划项目 (2022YFF0503900, 2022YFF0503902) 和国家自然科学基金项目 (U2341201, 62201326, 62571216) 共同资助

2025-05-09 收到原稿, 2025-08-13 收到修定稿

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

HAN Chao² ZHU Qinglin³ ZHEN Weimin³¹(College of Ocean Science and Engineering, Shandong University of Science and Technology, Qingdao 266590)²(College of Electronic and Information Engineering, Shandong University of Science and Technology, Qingdao 266590)³(China Research Institute of Radiowave Propagation, Qingdao 266107)⁴(School of Automation, Northwestern Polytechnical University, Xi'an 710129)

Abstract As a key parameter of the ionosphere, the critical frequency of the F_2 layer of the ionosphere (f_0F_2) is of great significance for ensuring the stable operation of systems such as high-frequency radar and short-wave communication. This paper proposes a short-term forecasting method for the ionospheric f_0F_2 based on deep learning. By using the Bidirectional Long Short-term Memory model with attention mechanism (BiLSTM-Attention) algorithm and combining the observed values of the ionospheric f_0F_2 at the ionosonde station for the previous 7 days, Universal Time (UT), solar activity index, and geomagnetic activity index as inputs, the forecasting of the ionospheric f_0F_2 in the Chinese region is realized. The results of the comparative analysis of the model show that: The forecasting errors for low-latitude stations were significantly higher than those for mid-latitude stations. The BiLSTM-Attention model demonstrated superior performance, followed by the Long Short-Term Memory (LSTM) model. Compared to the International Reference Ionosphere (IRI) model, the BiLSTM-Attention model achieved a 44.2% reduction in Root Mean Square Error (RMSE), 47% decrease in Mean Absolute Error (MAE), and 21.3% improvement in the Coefficient of Determination (R^2). During geomagnetic storms, the BiLSTM-Attention model successfully captured the negative storm effects (characterized by f_0F_2 depletion) in China's regional ionosphere, showing excellent consistency with observational data. However, even when operating in storm mode, the IRI model still exhibited noticeable deviations between predicted and observed f_0F_2 values. As the forecasting window extended from 1 hour to 24 hours, the model errors showed a systematic increasing trend: RMSE rose from 0.99 MHz to 2.05 MHz, MAE increased from 0.69 MHz to 1.57 MHz, while R^2 decreased from 0.93 to 0.75. Relevant research provides high-precision ionospheric parameter forecasting support for space weather warning and short-wave communication system optimization.

Key words Ionosphere, F_2 -layer critical frequency (f_0F_2), BiLSTM-Attention, Deep learning, Short-term forecasting

0 引言

电离层作为日地空间环境的重要耦合区域,其参数的精准预报对卫星导航、地基雷达、短波通信等国防与民用领域具有重大意义^[1]。在电离层预报技术领域,已提出多种模型与方法,主要包括经验模型、物理模型、统计方法、数据驱动方法和人工智能方法^[2]。经验模型如国际参考电离层模型(International Reference Ionosphere, IRI)和参数化电离层模型(Parameterized Ionospheric Model, PIM)。通过统计分析大量地基和天基观测数据并采用球谐函数、多项式、样条函数等经验建模技术,能够反映电离层的气候学平

均状态,但难以捕捉电离层瞬时变化,导致预测参量与实际电离层状态之间存在较大误差^[3]。物理模型从连续性方程、动量方程和能量方程出发,可以模拟不同空间和时间条件下的电离层变化,适用于长期预测与电离层机理研究。但物理模型的复杂性较高,涉及众多物理过程和参数,例如光电离和光化学反应、底层大气波动、高能粒子沉降等,导致计算量巨大。此外,这些模型严重依赖于外部输入数据,例如太阳辐射通量与地磁指数,这可能会影响预测精度^[4]。统计方法如自相关函数法(Auto Correlation Function, ACF)、自适应自回归(Adaptive Autoregressive, AAR)算法、整合移动平均自回归模型(Autoregressive In-

tegrated Moving Average, ARIMA) 方法, 主要依赖于历史数据的时间特征进行预测, 相关方法基于平稳性、季节性等特定假设, 难以实现高精度预测, 在实际应用中可能面临挑战^[5]. 电离层数据驱动方法, 如数据同化技术, 通过融合多源观测与背景模型, 动态优化背景场以提高预报精度, 其优势在于能有效利用实测数据修正模型偏差, 并提升短期预报的时空一致性; 但局限性在于计算复杂度高、对观测数据覆盖密度敏感, 且依赖背景模型的先验准确性^[6].

电离层 F_2 层临界频率 (F_2 -layer critical frequency, f_0F_2) 作为电离层的关键参数, 其准确预报对于保障高频雷达、短波通信等系统的稳定运行至关重要. 因此, 预测 f_0F_2 已成为电离层研究和应用中的重要关注点. 由于人工神经网络具有良好的非线性映射能力、自学习适应性和并行信息处理能力, 在电离层参量预测方面表现出较大的潜力, 能够较好地逼近和模拟电离层这一复杂的非线性系统^[7], 基于人工智能的电离层参数预报方法取得了飞速发展. 神经网络技术已成功应用于构建合适的预测模型来预测电离层参量^[8], 同时, 不同学者发展了各类新算法以提高神经网络的预测性能和准确性, 包括基于梯度下降的误差反向传播神经网络方法^[9]、改进的粒子群优化神经网络方法^[10]等. 近年来, 由于计算能力的提升, 深度学习凭借其在学习时间序列数据方面的优势, 在电离层预报领域得到了广泛应用. 与传统的神经网络模型不同, 深度学习模型能够推断时间序列数据中前一时间节点和后一时间节点之间的关系, 预报效果更佳^[11], 如长短期记忆网络 (Long Short-Term Memory, LSTM) 方法、循环神经网络 (Recurrent Neural Network, RNN) 方法、改进的门控循环单元 (Gated Recurrent Unit, GRU) 方法、LSTM 网络和改进型信号分解混合方法等^[8,12,13].

中国地域广阔, 不同地区的电离层特性存在差异, 且受到独特的地理、地磁条件影响, 使中国区域电离层 f_0F_2 的预报具有一定的复杂性和挑战性. 因此, 开展基于深度学习的中国区域电离层 f_0F_2 预报技术研究, 对于提升中国在空间环境监测与预报领域的的能力, 保障通信、雷达等系统的稳定运行具有重要的现实意义. 本文提出了一种基于深度学习的预报方

法, 通过采用注意力机制的双向长短期记忆网络 (Bidirectional Long Short-Term Memory Model with Attention Mechanism, BiLSTM-Attention) 算法, 结合电离层垂测站 f_0F_2 观测值、世界时、太阳活动指数及地磁活动指数作为输入, 实现了中国区域电离层 f_0F_2 的短期预报, 实测数据验证了方法的精度和有效性.

1 数据来源

研究表明, 电离层 f_0F_2 随太阳和地磁活动、地理经纬度、季节和时间呈现出复杂的非线性变化^[14,15]. 本文选择太阳、地磁活动指数、UT 时间、地理位置及观测台站预报前 7 天的 f_0F_2 等作为模型的输入, 模型的输出被设定为待预报的 f_0F_2 参数. 其中地磁活动指数选取了 Ap , Kp , Dst 指数, 太阳活动指数则选取了 v_{sw} (太阳风速)、 $F_{10.7}$ 指数 (10.7 cm 太阳射电通量), 以上数据来源于 NASA 戈达德太空飞行中心网站*. 通过各种组合, 上述参数被引入模型作为输入参数. 研究发现, 当上述所有参数均作为输入时, 模型的表现最佳. 作为模型的输入参数, 太阳、地磁等影响因素也需要以 1 h 分辨率进行排序, 以确保模型不同输入参数之间的采样间隔一致.

利用 2023 年 11 月至 2024 年 10 月共计一年的电离层垂测 f_0F_2 观测数据构建数据集, 电离层垂测站的具体分布如图 1 所示, 图 1 显示了中国境内 12 个电离层数字垂测仪的名称.

受电离层垂测设备故障、电磁信号干扰、电离层




图 1 中国区域电离层垂测台站分布

Fig. 1 Distribution of ionospheric ionosonde stations over China

* <https://omniweb.gsfc.nasa.gov/>




图2 青岛站电离层垂测仪的电离层 f_0F_2 数据预处理前后对比 (空白区域为数据缺失处)
Fig. 2 Comparison of ionospheric f_0F_2 before and after data preprocessing at Qingdao station (Blank areas indicate missing data)

扰动、数据处理误差以及人为操作失误或校准不当等因素的影响, 电离层垂测会有数据缺失的情况发生, 将对深度学习模型的训练造成不利影响. 为提升数据质量, 每个垂测站的原始观测数据经过离群值剔除、插值重采样等预处理, 被整理成 1 h 分辨率的数据. 如图 2 所示为青岛站 2023 年 11—12 月期间, 垂测站 f_0F_2 经过数据插值后的效果对比. 图 2(a) 为处理前 f_0F_2 分布, 空白区域即为数据缺失处; 图 2(b) 为预处理后的结果. 从图中可以看出, 经过数据预处理后, 大量的数据缺失情况得到了有效修复, 电离层 f_0F_2 的日变化和逐日变化特征更为明显, 数据预处理为深度学习提供了良好的数据支撑.

2 模型与方法

2.1 长短时记忆网络

长短时记忆网络 (LSTM) 是 Hochreiter^[16] 提出的一种旨在解决 RNN 模型梯度弥散问题的模型. LSTM 模型的内部结构由三个控制门组成: 输入门、遗忘门和输出门, 以此决定每一时刻信息的记忆与遗忘. 三个门由具有记忆功能的细胞单元 (cell) 连接, 广泛应用于时间序列预测^[17]. LSTM 计算公式如下.

神经元内部遗忘门输出 f_t 的计算公式为

$$f_t = \sigma(W_{x_f}x_t + W_{h_f}h_{t-1} + b_f). \quad (1)$$

其中, σ 表示 Sigmoid 激活函数; W_{x_f} , W_{h_f} 为遗忘门的权重; x_t 为当前时刻的输入; h_{t-1} 为 $t-1$ 时刻神经元的输出; b_f 为偏置项.

输入门在当前时刻的输出 i_t 的计算公式为

$$i_t = \sigma(W_{x_i}x_t + W_{h_i}h_{t-1} + b_i). \quad (2)$$

其中, W_{x_i} , W_{h_i} 为输入门的权重; b_i 表示偏置项.

更新门用来控制 LSTM 单元的状态 C 的更新, 更新公式为

$$\tilde{C}_t = \tanh(W_{x_c}x_t + W_{h_c}h_{t-1} + b_c). \quad (3)$$

其中, W_{x_c} , W_{h_c} 为输出门的权重; b_c 表示偏置项.

当前时刻 LSTM 单元的记忆 C_t 计算公式为

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

其中, C_{t-1} 为上一时刻 LSTM 单元的记忆.

最后, 结合输出门得到的输出及当前时刻 LSTM 单元的记忆 C_t , 计算得 h_t , 计算过程为

$$o_t = \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + b_o), \quad (5)$$

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

其中, W_{x_o} , W_{h_o} 为输出门的权重; b_o 表示偏置项; o_t 为神经元内部输出门的输出量; h_t 为当前时刻神经元的输出.

2.2 双向长短时记忆网络

LSTM 模型仅具备单向特征信息传递的特点. 相

比之下, 双向长短期记忆网络 (Bidirectional Long Short-Term Memory, BiLSTM) 神经网络模型的输入序列分别通过正序和逆序输入至两个 LSTM 神经网络进行特征提取, 再将两个输出向量进行拼接作为最终的特征信息, 通过双向信息流可以更好地捕捉序列中的上下文信息, 从数据中提取到双向时间特征, 以提高模型性能^[18]. BiLSTM 模型的正向、反向传播与输出计算可表示为

$$h_{t,f} = (x_t, h_{t-1,f})_{\text{LSTM}}, \quad (7)$$

$$h_{t,b} = (x_t, h_{t-1,b})_{\text{LSTM}}, \quad (8)$$

$$y_t = W_f h_{t,f} + W_b h_{t,b} + b_y. \quad (9)$$

其中, $h_{t,f}$, $h_{t,b}$ 为当前时刻正向 LSTM 隐含层的输出和反向 LSTM 隐含层的输出, $h_{t-1,f}$, $h_{t-1,b}$ 为前一时刻正向 LSTM 隐含层的输出和反向 LSTM 隐含层的输出; W_f 和 W_b 分别表示 $h_{t,f}$ 和 $h_{t,b}$ 的权重, b_y 为输出层对应的偏置.

2.3 注意力机制

在 BiLSTM 层后引入注意力机制. 该机制赋予模型对不同位置之间依赖关系的建模能力, 使模型能够在一个步骤内对整个输入序列进行处理, 并根据序列中元素的重要性动态地分配权重, 通过有效地捕捉序列中的相关信息来提高预测性能. 在 BiLSTM 注意力机制模型中, 注意力模块接收到 BiLSTM 模块输出的双向时间特征, 并根据序列中元素的重要性动态为特征赋予权重^[19].

在注意力机制模块, 首先计算特征与回归值之间的相似度, 得到注意力得分 δ_i , 即

$$\delta_i = \text{sim}(h_i, y_t) = h_i \cdot y_t. \quad (10)$$

其中, $\text{sim}(\cdot)$ 表示特征向量与目标回归值之间的相似度计算函数, h_i 为第 i 个位置的 BiLSTM 输出特征, y_t 为 t 时刻的回归目标值.

然后对注意力得分通过 softmax 函数进行归一化, 将原始计算分值整理为所有元素权重和为 1 的概率分布, 突出重要特征的权重, 其表达式为

$$a_i = \text{softmax}(\delta_i) = \frac{e^{\delta_i}}{\sum_{j=1}^{L_x} e^{\delta_j}}. \quad (11)$$

其中, δ_i , δ_j 分别为第 i , j 个位置的注意力得分; L_x 为输入序列的长度.

根据权重系数对特征进行加权求和, 得到加权特

征, 即

$$H_i = \sum_{i=1}^{L_x} a_i \cdot h_i. \quad (12)$$

2.4 训练和验证方法

整体而言, 2023 年 11 月至 2024 年 10 月属于太阳活动高年, 选择前序的 200 天的数据用于训练和交叉验证, 后序 165 天的数据用于测试. 模型使用训练集进行训练, 并选择损失函数和 1 天的均方根误差作为模型是否最优的参考, 深度学习过程中, 模型使用滑动窗口的方式进行逐步向前预报, 利用前 7 天的数据来预测未来 1 天内 24 个整点时刻的 f_0F_2 值, 最后利用测试集对训练后的深度学习模型进行精度评估.

在深度学习神经网络中, 选择合适的超参数是一个极其重要的步骤, 其会直接影响模型的性能. 然而, 到目前为止, 还未有统一的超参数确认方法, 常见的方法包括网格搜索法、随机搜索法、贝叶斯优化法等^[20]. 本研究采用网格搜索法来确定超参数. 该方法首先为每个参数设置几个典型的数值, 配置这些超参数数值的组合, 根据这些组合分别训练模型, 并通过比较选择最优的组合. 这种超参数选择方法可以有效防止局部过拟合^[20,21].

模型使用训练集进行训练, 并选择损失函数和 1 天的均方根误差作为判断模型是否最优的参考. 然后使用测试集的最优模型进行预报, 并计算预报精度. 模型输入参数值范围的大幅变化可能导致模型在优化过程中出现振荡. 为了解决这个问题, 需要对输入参数进行归一化处理. 使用归一化函数将所有数据缩放至 $[0, 1]$ 范围内, 并在输出前使用逆归一化将预报值恢复至实际大小. 模型的最终工作流程如图 3 所示.

3 结果与讨论

3.1 评估方法

为了测试双向长短期记忆网络-注意力 (BiLSTM-Attention) 模型的预测效果, 选取国际参考电离层模型 2020 模型 (IRI-2020)、长短期记忆网络 (LSTM) 模型进行对比分析. 当使用 IRI-2020 模型预测临界频率 f_0F_2 时, 开启国际无线电咨询委员会 (CCIR) 模式. 为体现 IRI-2020 模型对磁暴期间电离层变化的响应能力, IRI 模型同时开启了暴时 (STORM) 模式^[22]. 所有模型均使用相同的训练集、测试集划分方法以及输入数据, 以进一步对不同模型

进行比较和分析. 此外, 还从不同台站、不同地磁条件、不同预报时长等方面对不同模型的预测性能进行了评估.

为了评估和比较各模型的预测结果, 采用平均绝对误差 (MAE, e_{MAE})、均方根误差 (RMSE, e_{RMSE}) 以及决定系数 (R^2) 对所提出的深度学习算法在预测 f_0F_2 方面的效果进行了评估. e_{MAE} , e_{RMSE} , R^2 的计算公式为

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_t - y_p|, \tag{13}$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_t - y_p)^2}, \tag{14}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_t - y_p)^2}{\sum_{i=1}^n (y_t - \bar{y}_t)^2}. \tag{15}$$

其中, n 为样本总数, y_t 为观测样本 i 的真值, y_p 为样本 i 的预测值, $\bar{y}_t$ 为样本真值的平均值.

3.2 提前 1 h 预报性能分析

表 1 给出了 IRI-2020 模型、长短期记忆网络 (LSTM) 模型及双向长短期记忆网络-注意力 (BiLSTM-Attention) 模型中, 采用前文提及的后序 165 天独立测试数据 (2024 年 5 月 20 日至 10 月 31 日) 的提前 1 h 预测结果的均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 R^2 . 电离层垂测站按照地




图 3 基于深度学习的电离层 f_0F_2 预报实现流程

Fig. 3 Flowchart of the ionospheric f_0F_2 forecasting based on deep learning

表 1 中国区域 IRI-2020 模型、LSTM 模型和 BiLSTM-Attention 模型的 f_0F_2 观测值与预测值之间的 RMSE, MAE 和 R^2

Table 1 RMSE, MAE, and R^2 between observed and predicted values of f_0F_2 for the IRI-2020 model, LSTM model, and BiLSTM-Attention model in China

台站	IRI-2020			LSTM			BiLSTM-Attention		
	RMSE/MHz	MAE/MHz	R^2	RMSE/MHz	MAE/MHz	R^2	RMSE/MHz	MAE/MHz	R^2
广州	2.40	1.82	0.65	2.12	1.63	0.74	1.12	0.81	0.91
昆明	2.14	1.52	0.69	1.97	1.37	0.84	1.15	0.88	0.92
重庆	1.96	1.65	0.75	1.35	1.32	0.86	0.75	0.58	0.93
苏州	1.22	0.92	0.70	1.11	1.03	0.75	0.76	0.56	0.89
新乡	0.93	0.71	0.79	0.91	0.71	0.85	0.62	0.44	0.91
兰州	0.86	0.66	0.83	0.87	0.64	0.86	0.56	0.42	0.93
青岛	0.98	0.73	0.74	0.92	0.71	0.79	0.69	0.50	0.89
北京	0.91	0.71	0.76	0.90	0.71	0.77	0.60	0.43	0.91
伊犁	1.23	1.02	0.81	1.21	0.90	0.89	0.56	0.39	0.92
乌鲁木齐	0.94	0.72	0.84	0.81	0.70	0.88	0.53	0.41	0.95
长春	0.97	0.76	0.67	1.05	0.79	0.79	0.69	0.51	0.91
满洲里	0.99	0.76	0.73	0.94	0.86	0.87	0.61	0.44	0.93
统计平均	1.29	1.00	0.75	1.18	0.94	0.82	0.72	0.53	0.91

理纬度从低到高的顺序从上到下排列. 从表 1 可以看出, 整体而言, 对于 3 个模型从不同台站的表现, 低纬的广州、昆明等台站要比中纬区域的台站 (北京、长春等) 的预报精度低, 整体呈现纬度越低, 预报误差越高的趋势. 主要原因分析为, 中国低纬地区处于北半球电离层赤道异常区, 该区域受赤道电急流和等离子体漂移的强烈影响, 易形成不同尺度电离层扰动结构, 因此预报误差相比中纬区域更高, 而中纬度电离层变化相对平缓, 预测效果将更加稳定.

BiLSTM-Attention 模型在每个站点的 RMSE 和 MAE 显著低于 IRI 模型, 而 R^2 值显著提高. 对所有台站计算均方根误差 RMSE、平均绝对误差

MAE 和决定系数 R^2 的均值, 其中 IRI-2020 模型上述指标分别为 1.29 MHz, 1.00 MHz 和 0.75; LSTM 模型则为 1.18 MHz, 0.94 MHz 和 0.82; 而 BiLSTM-Attention 模型为 0.72 MHz, 0.53 MHz 和 0.94. LSTM 模型相比 IRI 模型的 RMSE 降低了 8.5%, MAE 降低了 6%, R^2 值提高了 8.5%; 而 BiLSTM-Attention 模型的 RMSE 降低了 44.2%, MAE 降低了 47%, R^2 值提高了 21.3%. 这表明 BiLSTM-Attention 模型优于其他模型, 并且在预报不同纬度的 f_0F_2 时间序列上均表现更佳. LSTM 模型性能介于 IRI 模型和 BiLSTM-Attention 模型之间, LSTM 模型预报性能优于 IRI 经验模型.




图 4 磁暴期不同模型电离层 f_0F_2 预报效果对比

Fig. 4 Comparison of f_0F_2 forecast performance among different ionospheric models during a geomagnetic storm period

3.3 磁暴期间预报效果分析

2024年8月11日发生了地磁暴,其中8月11日夜間地磁 Dst 指数快速下降,12日17:30 UT 达到最大强度, Dst 指数最低下降至 -188 nT,直到15日才恢复正常水平,大量太阳风与磁层能量注入地球大气,引发电离层环境剧烈扰动。图4从上到下依次给出了2024年8月11—17日期间地磁 Dst 指数,以及广州、昆明、满洲里3个台站实测电离层 f_0F_2 、IRI模型、LSTM模型和 BiLSTM-Attention 模型(图4分别用 OBS, IRI, LSTM 和 BiLSTM-Attention 表示)提前1 h 预报效果。从图4可以看出,磁暴发生期间,中国区域出现了较为明显的负暴效应,昆明、满

洲里、广州的电离层均出现明显下降。IRI-2020 模型开启暴时模式后,磁低纬区域广州和昆明站预测的电离层 f_0F_2 出现了小幅度降低,但相对变化并不明显,中纬度的满洲里台站呈现明显负暴效应,与实测结果基本变化趋势较为一致,但部分时段 f_0F_2 预测结果与实测值依然存在较明显偏差,而 LSTM 和 BiLSTM-Attention 模型则能够较好地预测出磁暴期间 f_0F_2 的变化,其中 BiLSTM-Attention 模型与实测值间的一致性最佳。

为了方便对比,图5同时给出了2024年7月4—10日磁静日的预报效果。从图5中可以看出,相较磁暴期间而言,地磁平静期间 IRI 模型与观测值之




图5 磁平静期不同模型电离层 f_0F_2 预报效果对比

Fig. 5 Comparison of f_0F_2 forecast performance among different ionospheric models during geomagnetically quiet periods

间相对较为一致,但在很多时刻(如日落后),与观测值之间仍存在较明显差距.从 LSTM 与 BiLSTM-Attention 模型的对比结果来看,BiLSTM-Attention 模型引入双向处理及注意力机制后,避免了 LSTM 单向模型的局部性局限,提升了 f_0F_2 对复杂依赖关系的捕捉能力,预报性能明显提升.

3.4 不同提前预报时间性能对比

电离层作为高层大气的电离成分,受太阳辐射条件控制,无法在较长时间尺度上保留过去的状态信息,通常仅有 2~3 h 的提前预报时间^[23,24].但电离层不同提前量的预报需求对应多样化的应用场景,如通信链路实时修正需 1~3 h 预报,空间天气预警依赖 12~24 h 预测,明确各时间提前量的预报误差的增长规律,可为模型优化与业务化应用提供量化依据.因此,设计了多时间维度的电离层 f_0F_2 对比实验,旨在揭示预报时效对模型性能的约束机制,为电离层动态自适应预报策略的构建提供支持.基于 BiLSTM-Attention 模型,对比试验分别对比了提前 1, 2, 3, 12,

24 h 的预报效能.不同预报提前量情况下,验证数据集的效果如图 6 所示.图 6 中采用了散点密度图的表现形式,图中横轴为观测数据,纵轴为预报数据,颜色代表数据样本的归一化密度,颜色越深,代表样本越密集.从图 6 可以看出,不同预报提前量下电离层 f_0F_2 的预报精度呈现显著差异,随着预报时间的增加,电离层的预报误差逐步增大.随着预报时间从 1 h 延长至 24 h,误差指标系统性上升:均方根误差 RMSE 从 0.99 MHz 增至 2.05 MHz;平均绝对误差 MAE 从 0.69 MHz 增至 1.57 MHz;决定系数 R^2 则由 0.93 减至 0.75. 1~3 h 短时预报的散点密集分布于 x - y 轴对称线附近,表明预报值与观测值高度线性相关;而长时预报(24 h)的散点分布明显发散,反映预报系统对电离层日变化的跟踪能力显著弱化.由此可看出,小时级短时预报主要受实时扰动影响建模精度,而更长时预报需克服更多周期性变化与突发太阳、地磁、底层大气波动等活动的双重不确定性,要提升中长期电离层 f_0F_2 的预报精度仍面临较大问题.




图 6 不同预报提前时间情况下电离层 f_0F_2 预报误差分析

Fig. 6 Error analysis of ionospheric f_0F_2 forecasts under different forecast advance time

4 结论

引入了一种基于注意力机制的双向长短期记忆网络 (BiLSTM-Attention) 模型, 用于预测中国区域电离层临界频率 (f_0F_2)。模型的输入数据包括来自电离层垂测站的 f_0F_2 数据、观测时刻、地磁活动指数 (Dst , A_p , K_p) 以及太阳活动指数 (v_{sw} , $F_{10.7}$), 对不同纬度台站、不同地磁条件下 LSTM, BiLSTM-Attention 等深度学习模型及 IRI-2020 模型的 f_0F_2 预测值和观测值进行了比较, 并分析了不同预报时长条件下电离层 f_0F_2 的预报性能。基于均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 R^2 的分析结果得出如下结论。

(1) 低纬的广州、昆明等台站要比中纬区域台站 (例如北京、长春等) 的预报精度要低; LSTM 和 BiLSTM-Attention 和模型均能成功预测 f_0F_2 的非线性变化, IRI 模型表现最差, 而 BiLSTM-Attention 模型表现最佳。与 IRI 模型相比, BiLSTM-Attention 模型 RMSE 降低了 44.2%, MAE 降低了 47%, R^2 值提高了 21.3%。

(2) 磁暴期间, 中国区域 (昆明、满洲里、广州) 电离层呈现显著负暴效应 (f_0F_2 下降), IRI 模型开启暴时模式后, 预测效果与实际观测值之间符合性更好; 但对比而言, LSTM 和 BiLSTM-Attention 模型能有效预测暴时变化, 其中 BiLSTM-Attention 通过双向时序处理和注意力机制克服单向模型的局部性局限, 在暴时与实测值一致性最优; 地磁平静时, IRI 模型虽与观测值整体接近, 但在很多时段仍存在明显误差。

(3) 随着预报时间从 1 h 延长至 24 h, 误差指标系统性上升。均方根误差 (RMSE) 从 0.99 MHz 增至 2.05 MHz, 平均绝对误差 MAE 从 0.69 MHz 增至 1.57 MHz, 决定系数 R^2 则由 0.93 减至 0.75。

目前, 深度学习在电离层 f_0F_2 预报中表现出显著优势, 但仍存在一些局限。依赖高质量数据, 但低纬/赤道区观测稀疏, 导致模型泛化能力受限; 极端空间天气事件 (例如超级磁暴) 的预测稳定性不足; 模型物理可解释性较弱, 难以揭示电离层演化的内在机制。未来需融合多源数据, 提升样本多样性, 开发物理约束的混合深度学习框架, 并优化实时自适应算法以应对突发扰动, 同时结合可解释性人工智能技术, 以增强预报结果的信度支撑, 这也是本文未来的研究方向。

利益冲突 所有作者均声明不存在利益冲突。

参考文献

- [1] ZHEN Weimin, OU Ming, YU Xiao, *et al.* Ionospheric Measurement and Application Technology Based on Satellite Beacon Signals[M]. Beijing: National Defense Industry Press, 2022 (甄卫民, 欧明, 於晓, 等. 卫星信号电离层探测及应用技术 [M]. 北京: 国防工业出版社, 2022)
- [2] ZHEN Weimin, OU Ming, ZHU Qingling, *et al.* Review on ionospheric sounding and modeling[J]. *Chinese Journal of Radio Science*, 2023, **38**(4): 625-645 (甄卫民, 欧明, 朱庆林, 等. 电离层探测及模化技术研究综述 [J]. *电波科学学报*, 2023, **38**(4): 625-645)
- [3] BILITZA D, PEZZOPANE M, TRUHLIK V, *et al.* The International Reference Ionosphere Model: a review and description of an ionospheric benchmark[J]. *Reviews of Geophysics*, 2022, **60**: e2022RG000792
- [4] HUBA J, MAUTE A, CROWLEY G, *et al.* SAMI3_ICON: model of the ionosphere/plasmasphere system[J]. *Space Science Reviews*, 2017. DOI:10.1007/s11214-017-0415-z
- [5] XUE Kai, SHI Chuang, WANG Cheng. RA-ConvLSTM: recurrent-architecture attentional ConvLSTM networks for prediction of global total electron content[J]. *Space Weather*, 2025, **23**: e2024SW004173
- [6] OU Ming, CHEN Longjiang, ZHEN Weimin, *et al.* Construction and implementation of a near-real-time global ionospheric data assimilation and forecasting system[J]. *Chinese Journal of Radio Science*, 2024, **39**(2): 313-321 (欧明, 陈龙江, 甄卫民, 等. 一种近实时全球电离层数据同化和预报系统的构建与实现 [J]. *电波科学学报*, 2024, **39**(2): 313-321)
- [7] CANDLER L R, MILOSAVLJEVIC M M, STANKOVIC S S, *et al.* Ionospheric forecasting technique by artificial neural network[J]. *Electron Lett*, 1998, **34**(16): 1573-1574
- [8] LI Xiaojun, ZHOU Chen, TANG Qiong, *et al.* Forecasting ionospheric f_0F_2 based on deep learning method[J]. *Remote Sensing*, 2021, **13**(19): 3849
- [9] Wang R, Zhou C, Deng Z, *et al.* Predicting f_0F_2 in the China region using the neural networks improved by the genetic algorithm[J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2013, **92**: 7-17
- [10] HU Xiaoxi, ZHOU Chen, ZHAO Jun, *et al.* The ionospheric f_0F_2 prediction based on neural network optimization algorithm[J]. *Chinese Journal of Radio Science*, 2018, **33**(6): 708-716 (胡小希, 周晨, 赵军, 等. 基于优化神经网络算法的电离层 f_0F_2 预测 [J]. *电波科学学报*, 2018, **33**(6): 708-716)
- [11] OLIVEIRA T P, BARBAR J S, SOARES A S. Computer network traffic prediction: a comparison between traditional and deep learning neural networks[J]. *International Journal of Big Data Intelligence*, 2016, **3**(1): 28-37

- [12] SHI Yafei, YANG Cheng, WANG Jian, *et al.* A forecasting model of ionospheric f_0F_2 using the LSTM network based on ICEEMDAN decomposition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1-16
- [13] SHI Yafei, YANG Cheng, WANG Jian, *et al.* A hybrid deep learning-based short-term forecast model for ionospheric f_0F_2 in East Asia region[J]. *Advances in Space Research*, 2025, **75**(1): 1-12
- [14] LIU Z D, FANG H X, WENG L B, *et al.* A comparison of ionosonde measured f_0F_2 and IRI-2016 predictions over China[J]. *Advances in Space Research*, 2020, **63**(6): 1926-1936
- [15] CHEN Longjiang, ZHEN Weimin, OU Ming, *et al.* A method of ionospheric f_0F_2 reconstruction in low and middle latitudes of the world based on stepwise linear optimal estimation[J]. *Chinese Journal of Radio Science*, 2021, **36**(1): 36-42 (陈龙江, 甄卫民, 欧明, 等. 一种基于分步线性最优估计的全球中低纬区域电离层 f_0F_2 重构方法 [J]. 电波科学学报, 2021, **36**(1): 36-432)
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, **9**(8): 1735-1780
- [17] 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, 张瀚铭, 刘子君, 丁锋, 赵必强. 基于长短时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)
- [18] JIANG Z, ZHANG Z, HE Y Y H. Efficient and accurate TEC modeling and prediction approach with random forest and Bi-LSTM for large-scale region[J]. *Advances in Space Research*, 2024, **73**(1): 650-662
- [19] HAN C, GUO Y, OU M, *et al.* A lightweight prediction model for global ionospheric total electron content based on attention-BiLSTM[J]. *Advances in Space Research*, 2025, **75**(4): 3614-3629
- [20] TANG J, YANG D, DING M. Forecasting ionospheric f_0F_2 using bidirectional LSTM and attention mechanism[J]. *Space Weather*, 2023, **21**: e2023SW003508
- [21] LIN Ziyang, CHEN Longjiang, JIN Ruimin, *et al.* A random forest-based prediction model for ionospheric f_0F_2 in China and surrounding regions[J]. *GNSS World of China*, 2024, **49**(5): 88-96 (林子扬, 陈龙江, 靳睿敏, 等. 基于随机森林算法的中国及周边区域电离层 f_0F_2 预测模型 [J]. 全球定位系统, 2024, **49**(5): 88-96)
- [22] ARAUJO-PRADERE E A, FULLER-ROWELL T J, CODRESCU M V. STORM: an empirical storm-time ionospheric correction model, 1 model description[J]. *Radio Science*, 2002, **37**(5): 1070. DOI:10.1029/2001RS002467
- [23] HE J, YUE X, WANG W, *et al.* EnKF ionosphere and thermosphere data assimilation algorithm through a sparse matrix method[J]. *Journal of Geophysical Research: Space Physics*, 2019, **124**: 7356-7365
- [24] OU Ming, CHEN Longjiang, WANG Yan, *et al.* Impact analysis of ground-based GNSS and space-based occultation observations on global ionospheric data assimilation[J]. *Chinese Journal of Radio Science*, 2022, **37**(4): 619-628 (欧明, 陈龙江, 王妍, 等. 地基 GNSS 和天基掩星观测对全球电离层数据同化效果的影响分析 [J]. 电波科学学报, 2022, **37**(4): 619-628)

作者简介



欧 明 男, 1984 年 10 月出生于江西省赣州市, 现为山东科技大学海洋科学与工程学院教授, 主要从事电波环境探测、电波传播及建模技术研究。

E-mail: ohm1122@163.com



韩 超 (通信作者) 男, 1984 年 3 月出生于山东省潍坊市, 现为山东科技大学电子信息工程学院副教授, 主要研究方向为卫星导航对抗、无线电波传播技术。

E-mail: skd996151@sdu.edu.cn