

融合电离层参数相似特征的 f_0F_2 参数 深度学习预测方法

郑丹丹¹ 陈亮² 王俊江² 柳文¹

1(湘潭大学自动化与电子信息学院 湘潭 411100)

2(中国电波传播研究所 青岛 266107)

摘要 电离层临界频率 f_0F_2 参数是重要的电离层参数之一, 开展 f_0F_2 参数预测具有重要的研究意义和应用价值. 提出了一种融合 f_0F_2 参数变化特性的深度学习预测方法, 采用双向长短时记忆神经网络 (BiLSTM) 和电离层参数相似特征相结合的模型实现电离层临界频率 f_0F_2 参数提前 24 h 预测. 结果表明, BiLSTM 结合电离层参数相似特征模型预测 f_0F_2 参数的平均相对误差在 8%~10%. 对不同纬度的探测站的 f_0F_2 参数预测结果表明, 随着纬度降低, 预测难度和误差都会增大, 预测精度降低. 对地磁暴期间的 f_0F_2 参数预测结果分析发现, 地磁暴期间的预测效果会受到一定程度的干扰, 预测误差增大. 在地磁暴期间, 相比长短时记忆神经网络 (LSTM) 模型和 BiLSTM 模型, BiLSTM 结合电离层参数相似特征模型对于 f_0F_2 参数的预测效果更优.

关键词 电离层临界频率, 深度学习, 双向长短时记忆神经网络 (BiLSTM), 地磁暴
中图分类号 P352

Deep Learning Prediction Method for f_0F_2 Parameters Based on the Ionospheric Parameter Similarity Features

ZHENG Dandan¹ CHEN Liang² WANG Junjiang² LIU Wen¹

1(Automation and Electronic Information College, Xiangtan University, Xiangtan 411100)

2(China Research Institute of Radiowave Propagation, Qingdao 266107)

Abstract The ionosphere is an important component of the solar terrestrial space environment, and the critical frequency f_0F_2 parameter is one of the most important and complex ionospheric parameters. The changes in f_0F_2 parameters will have a certain degree of impact on communication, navigation, radar and other technologies, so predicting f_0F_2 parameters has important research significance and application value. This article proposes a deep learning prediction method that integrates the characteristics of f_0F_2 parameter changes. A model combining bidirectional long short-term memory neural network BiL-

2023-10-09 收到原稿, 2024-01-20 收到修定稿

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

STM network and ionospheric parameter similarity features is used to predict the ionospheric critical frequency f_0F_2 parameter 24 hours in advance. The results show that the average relative error of BiLSTM combined with ionospheric parameter similarity model in predicting f_0F_2 parameters is about 8%~10%. Compared with the Long Short-Term Memory (LSTM) model, the average relative error has decreased by about 6% to 7%, while compared with the BiLSTM model, the average relative error has decreased by about 4% to 5%. The prediction results of the f_0F_2 parameter for different latitude detection stations show that as the latitude decreases, the difficulty of predicting the f_0F_2 parameter increases, the prediction errors of the three models increase, and the prediction accuracy decreases. The analysis of the prediction results of f_0F_2 parameters during geomagnetic storms shows that the predictive performance of the three models will be affected to varying degrees during the occurrence of geomagnetic storms, and the prediction error will increase. Compared to the calm period, the average relative error of the three models has increased by about 1% to 4%. During geomagnetic storms, compared with LSTM and BiLSTM models, BiLSTM combined with ionospheric parameter similarity feature models has better predictive performance for f_0F_2 parameters and better predictive performance. This method can also be applied to the prediction research of other ionospheric parameters such as Total Electron Content (TEC), h_mF_2 , etc., and has a very broad application prospect.

Key words Ionospheric critical frequency, Deep learning, Bidirectional Long Short-Term Memory neural network (BiLSTM), Geomagnetic storm

0 引言

地球电离层^[1]是地球高层大气的电离部分, 距离地球表面约 50~1000 km, 对太阳和磁层能量输入的变化有明显的反应. 电离层对无线通信、雷达定位及军事等方面都有重要的影响, 因此对电离层参数进行预测, 具有十分重大的研究意义.

近几十年来, 为了能够更快更准确地获得电离层参数信息, 专家已研究出许多方法预测电离层参数. 例如国际参考电离层 (IRI) 模型^[2-4]、自协方差方法^[5]、基于非线性径向基函数方法^[6]、自回归移动平均模型 (ARIMA)^[7]等方法, 但以上方法不能很好地反映 f_0F_2 数据之间的非线性关系, 预测精度不高. 神经网络是一种数据驱动的技术, 它能有效地从大数据中吸收大量信息, 学习样本数据的内在规律和表示层次. 近几年专家们逐渐意识到电离层的各类参数的短期变化具有随机性的特点, 因此人工神经网络技术开始被应用到电离层各种参数的预报中.

近年来, Yuan 等^[8]发现, 深度学习递归神经网络 (RNN) 可以解决全连接的深度神经网络 (DNN) 无法对时间序列变化进行建模的问题, 且能更好地捕捉时间序列数据的信息, 对预测时间序列数据有一定的帮助, 于是建立了基于 RNN 网络的电离层总电子

含量 (TEC) 提前 24 h 预测模型, 结果表明 RNN 预测精度优于反向传播神经网络 (BPNN). 然而, Gers 等^[9]提出的 RNN 算法存在消失梯度和爆炸梯度问题, 为解决这两个问题, 其在 RNN 模型的基础上进行改进, 研究出了长短时记忆神经网络 LSTM(Long Short-Term Memory) 模型. Moon 等^[10]采用 LSTM 网络模型, 利用太阳和地磁指数数据, 提前 24 h 预测济州岛探测站的 f_0F_2 和 h_mF_2 参数. Srivani 等^[11]使用 LSTM 网络预测了孟加拉鲁鲁站第 24 个太阳周期的 8 年 GPS 总电子含量. Siarni-namini 等^[12]发现, 增加 LSTM 的网络层数能够有效地提升模型性能, 因此研究出了双向 LSTM 网络——BiLSTM(Bidirectional Long Short-Term Memory). Hu 等^[13]采用 BiLSTM 网络, 利用历史 5 h 的日地数据预测未来 1 h 的 h_mF_2 参数, 实验结果表明 BiLSTM 网络模型的预测性能优于 LSTM 网络模型. Rao 等^[14]利用 BiLSTM 网络预测低纬度探测站地磁暴期间的 f_0F_2 和 h_mF_2 参数, 结果表明 BiLSTM 网络比 LSTM 网络、神经网络 (NN) 和国际参考电离层 (IRI) 2016 模型表现得更好. 以上工作都较好地显示了 BiLSTM 在电离层参数预测方面的有效性和良好的应用前景.

考虑到日地数据获取具有一定的难度, 且电离层临界频率 f_0F_2 参数具有明显的 24 h 日变化特征, 因

此本文考虑仅采用电离层参数自身的时间序列作为输入, 使用双向长短时记忆神经网络——BiLSTM 结合电离层参数相似特征的方法, 利用历史 24 h 的电离层临界频率 f_0F_2 参数预测未来 24 h 的 f_0F_2 参数. 结果表明, 采用 BiLSTM 结合电离层参数相似特征的方法对 f_0F_2 进行预测比 LSTM 网络模型和 BiLSTM 网络模型误差更小, 预测效果更好.

1 模型建立

1.1 神经网络模型

基于深度学习的方法, 采用双向长短时记忆神经网络 BiLSTM 对待预测日 24 h 的电离层临界频率 f_0F_2 参数进行初步预测, 接着利用相似度理论, 计算并选择与待预测日的初步预测值相似度最高的历史日数据作为第二次输入, 最终预测待预测日 24 h 的 f_0F_2 参数.

与传统的直接利用待预测日前 24 h 历史数据作为输入的方法不同, 基于电离层参数数据之间的相似特征, 使用相似度理论对历史日数据进行筛选, 将相似度最高的历史数据作为输入, 能够提高历史日和标签值之间的关联性, 减小由于人工或环境等带来的干扰和数据误差, 使得神经网络在训练时能够更加准确地学习到 f_0F_2 参数之间的内在关系, 从而提升预测结果的精度.

BiLSTM 神经网络是将两个传播方向相反的 LSTM 模型进行叠加. LSTM 网络结构图如图 1 所示, LSTM 引入了三个门, 包括遗忘门、输入门和输出门, 用于保护和控制细胞的状态, 并共同构成了 LSTM 的隐藏层, 其计算公式如下.

遗忘门

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t]) + b_f; \quad (1)$$

输入门

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2)$$

$$c'_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c), \quad (3)$$

$$c_t = f_t c_{t-1} + i_t c'_t; \quad (4)$$

输出门

$$\tilde{o}_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (5)$$

$$h_t = \tilde{o}_t \tanh(c_t). \quad (6)$$

其中, W_f, W_i, W_c, W_o 为权重参数, b_f, b_i, b_c, b_o 为偏置项.

BiLSTM 的网络结构如图 2 所示, 在第一层中, 将序列正向地输入 LSTM 模型, 在第二层中, 输入序列的反向形式被输入到 LSTM 模型. 双向使用 LSTM 可以改善学习的长期依赖性, 从而提高模型的准确性.

由图 2 可以看出, 第一层的正向计算, 隐藏层的 h_t 与 h_{t-1} 有关; 第二层的反向计算, 隐藏层的 h'_{t-1} 与 h'_t 有关, 具体的计算方式如下:

$$h_t = f(Ux_t + Wh_{t-1}), \quad (7)$$

$$h'_{t-1} = f(U'x_t + W'h'_t). \quad (8)$$

其中, U 和 U' 为输入层的权重, W 和 W' 为隐藏层的权重. 输出 o_t 由正向隐藏层输出和反向隐藏层输出共同决定, 计算公式如下:

$$o_t = g(Vh_t + V'h'_t + b_o). \quad (9)$$

其中, V, V' 为权重, b_o 为偏置项.

1.2 电离层相似度计算

考虑到 f_0F_2 参数非线性特性较强, 太阳、地磁活




图 1 LSTM 神经网络结构
Fig. 1 LSTM neural network structure diagram




图2 BiLSTM神经网络结构

Fig. 2 BiLSTM neural network structure diagram

动及人工误差对电离层 f_0F_2 参数的影响较大, 因此采用融合电离层相似特征的方法, 减少外部因素对数据的干扰, 加强数据之间的关联性, 利于神经网络更好地学习数据之间的变化关系, 以此来提高预测精度. 相似特征方法主要利用了相似度原理, 其关键在于计算两组时序序列所描述的曲线之间的形状相似性, 按下式计算:

$$R_{X_i Y_j} = \frac{2[E(X_i Y_j) - E(X_i)E(Y_j)]}{D(X_i) + D(Y_j)}. \quad (10)$$

其中, $X_i = (X_{i1}, X_{i2}, \dots, X_{it})$ 为历史日的 f_0F_2 数据, $Y_j = (Y_{j1}, Y_{j2}, \dots, Y_{jt})$ 为预测的 f_0F_2 数据, E 代表数学期望, D 代表方差; 相似度 $R_{X_i Y_j}$ 的取值范围在 $(0,1)$ 之间, 相似度 $R_{X_i Y_j}$ 越大表明两组时间序列数据之间的曲线形状越接近, 关联性越强. 需要注意的是, 如果取时间序列长度 t 为 24 h, 即为电力负荷短期预测^[15,16] 和电离层参数短期预测^[17,18] 相似日的概念.

1.3 预测模型

采用提前 24 h 预测未来 24 h 的电离层临界频率 f_0F_2 参数, 基于电离层参数相似特征的深度学习预测模型的训练过程中共包含两个独立训练的网络, 训练步骤如下.

步骤 1 利用训练集数据训练第一个 BiLSTM 神经网络 (为便于区分, 称其为连续 24 h 预测网络).

步骤 2 基于训练集中第 i 日的 f_0F_2 参数实测值, 计算第 i 日的 f_0F_2 参数实测值与其前 K 日的 f_0F_2 参数之间的相关度大小, 由于时间跨度太大的数据会影响数据之间的相关性, 因此本研究中 $K = 10$, 即令第 i 日的前 10 天的历史 f_0F_2 数据分别与第 i 日的实测值

进行相似度计算.

步骤 3 对计算出的 K 个相似度进行排序, 取最大相似度对应的那天的 f_0F_2 数据作为相似特征历史日数据, 第 i 天的实测 f_0F_2 参数作为相似特征的标签值, 组成一组相似特征数据, 一组相似特征数据一共包含了 48 h 的数据, 以此类推. 将所有相似特征数据组聚类为相似特征训练集, 并利用相似特征训练集训练第二个 BiLSTM 神经网络 (为便于区分, 称其为相似特征网络).

基于电离层参数相似特征的深度学习预测模型的预测步骤如下.

步骤 1 将待预测的第 j 日前 24 h 的 f_0F_2 参数输入连续 24 h 预测网络, 输出第 j 日 24 h 的 f_0F_2 参数预测值.

步骤 2 基于第 j 日的预测值, 计算第 j 日的 f_0F_2 参数预测值与其前 K 日的 f_0F_2 参数之间的相关度大小.

步骤 3 对计算出的 K 个相似度进行排序, 取最大相似度对应的那天的 f_0F_2 数据作为第 j 日的相似特征历史日数据.

步骤 4 将第 j 日的相似特征历史日数据输入相似特征网络, 输出最终的第 j 日的 f_0F_2 参数预测值.

完整的训练和预测流程如图 3 所示.

使用 Python 语言和 Pytorch 框架编写深度学习代码, 搭建神经网络, 经过不断实验与调整参数, 确定使用均方误差 (Mean-Square Error, MSE) 作为损失函数, 优化器采用 Adam 优化器, 网络训练的详细参数列于表 1.




图 3 基于电离层参数相似特征的深度学习预测模型的训练及预测流程

Fig. 3 Training and prediction flowchart of a deep learning prediction model based on ionospheric parameter similarity features

表 1 网络训练参数

Table 1 Network training parameters

Name	Number
Hidden size	128
Batch size	10
Learning rate	0.001
Epochs	200

2 预测结果分析

2.1 实验数据来源

研究采用的电离层临界频率 f_0F_2 参数数据由 Lowell GIRO 数据中心 (LGDC)^[19] 提供, 数据单位为 MHz, 时间分辨率是 1 h. 由于电离层临界频率 f_0F_2 数据存在周期性的 24 h 日变化, 因此本研究采用历史 24 h 的 f_0F_2 数据预测未来 24 h 的 f_0F_2 参数,

即网络输入为历史 24 h 的 f_0F_2 参数, 输出为未来 24 h 的 f_0F_2 参数.

选取 BOULDER, CHILTON, BOA 三个电离层探测站 2014 年 1 月 1 日至 2015 年 12 月 31 日的 f_0F_2 参数数据作为数据集. 对三个探测站的数据集首先进行连续 48 h 的划分处理, 即将每 48 h 的数据作为一组样本数据, 其中前 24 h 为历史数据, 后 24 h 为标签数据, 每个探测站的总样本共包含 9340 组连续 48 h 的数据组. 对 9340 组总样本数据进行划分, 其中前 80% 的数据作为模型的训练集, 后 20% 作为测试集以验证模型的预测性能, 测试数据集与训练集独立, 且测试实例来源于测试集, 参与训练的数据不用于预测性能的测试. 三个探测站信息如表 2 所示.

2.2 评价指标

为了能够客观地评价每个模型的预测结果, 采用

均方根误差 (RMSE, E_{rms})、平均绝对误差 (MAE, E_{ma})、平均相对误差 (MAPE, E_{map}) 来计算误差, 即

$$E_{\text{rms}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_{\text{ob}} - f_{\text{pr}})^2}, \tag{11}$$

$$E_{\text{ma}} = \frac{1}{N} \sum_{i=1}^N |f_{\text{ob}} - f_{\text{pr}}|, \tag{12}$$

$$E_{\text{map}} = \frac{1}{N} \sum_{i=1}^N \frac{|f_{\text{ob}} - f_{\text{pr}}|}{f_{\text{ob}}}. \tag{13}$$

其中, f_{ob} 为实测值, f_{pr} 为预测值, N 为数据样本总数.

2.3 结果分析

按照图 3 中的网络结构构建预测模型, 使用 LSTM 模型、BiLSTM 模型、BiLSTM 结合电离层参数相似特征法分别对 BOULDER, CHILTON, BOA 三个探测站测试集的电离层临界频率 f_0F_2 参数进行预测, 计算三种模型下三个探测站的 f_0F_2 参数预测结果误差并进行比较分析.

使用三种评价指标, 即均方根误差 (RMSE)、平

表 2 电离层探测站信息
Table 2 Information of ionospheric detection stations

URSI	Station	Country	Latitude (N)/(°)	Longitude (W)/(°)
BVJ03	BOA	Brazil	2.8	60.7
BC840	BOULDER	America	40.0	105.3
RL052	CHILTON	Canada	51.5	100.6

表 3 三个模型的 f_0F_2 参数观测值和预测值之间的误差
Table 3 Errors between observed and predicted values of f_0F_2 parameters for three models

Station	LSTM			BiLSTM			BiLSTM结合相似特征法		
	RMSE /MHz	MAE /MHz	MAPE /(%)	RMSE /MHz	MAE /MHz	MAPE /(%)	RMSE /MHz	MAE /MHz	MAPE /(%)
BOA	1.454	1.063	16.21	1.327	1.065	14.30	1.067	0.751	10.04
BOULDER	1.067	0.825	15.28	1.003	0.724	13.54	0.694	0.513	8.61
CHILTON	1.045	0.796	14.27	0.864	0.629	11.87	0.581	0.415	7.94




图 4 2015 年 10 月 4 日 00:00 LT–23:00 LT 期间三个探测站的 f_0F_2 参数预测结果
Fig. 4 Prediction results of f_0F_2 parameters for three detection stations from 00:00 LT to 23:00 LT on 4 October 2015

均绝对误差 (MAE)、平均相对误差 (MAPE), 评估三种模型的性能和预测能力. LSTM 模型、BiLSTM 模型和 BiLSTM 结合相似特征法之间的预测误差比较结果列于表 3. 图 4 描述了测试集中 2015 年 10 月 4 日 00:00 LT 至 2015 年 10 月 4 日 23:00 LT 期间共 24 h 的三个探测站的 f_0F_2 参数预测结果对比. 结合表 2、表 3 和图 4 可以看出, 在三个探测站中, BOA 探测站位于低纬度, 其预测误差相较于 BOULDER 和 CHILTON 两个中纬度的探测站都要大, 预测结果受到的干扰更大, 表明探测站纬度的高低对预测结果有重要影响. 而对于同一个探测站来说, 本文方法预测效果更好. 例如在 CHILTON 探测站, LSTM 模型的均方根误差为 1.045 MHz, 平均绝对误差为 0.796 MHz, 平均相对误差为 14.27%, BiLSTM 模型的均方根误差为 0.864 MHz, 平均绝对误差为 0.629 MHz, 平均相对误差为 11.87%, BiLSTM 结合相似特征法的均方根误差为 0.581 MHz, 平均绝对误差为 0.415 MHz, 平均相对误差为 7.94%. 相较于 LSTM 模型, BiLSTM 结合相似特征法的均方根误差、平均绝对误差、平均相对误差三种预测误差分别减小了 0.464 MHz, 0.381 MHz, 6.33%. 相较于 BiLSTM 模型, BiLSTM 结合相似特征法的均方根误差、平均绝对误差、平均相对误差三种预测误差

分别减小了 0.283 MHz, 0.214 MHz, 3.93%. 由此可见, BiLSTM 结合电离层参数相似特征法模型在电离层临界频率 f_0F_2 参数预测方面有较大的优势.

Dst 指数是一种地磁指标, 可监视全世界的磁暴水平, 地磁暴的发生会致使电离层参数产生较大幅度的变化, 当地磁指数 $Dst < -30$ nT 时可认为此时发生了地磁暴事件, 当地磁指数 $Dst < -100$ nT 时可认为此时发生了大地磁暴事件. 图 5 描述了 LSTM 模型、BiLSTM 模型及 BiLSTM 结合相似特征法对测试集中 2015 年 12 月 19 日 15:00 LT 至 2015 年 12 月 21 日 14:00 LT 地磁暴期间 BOULDER 探测站的 f_0F_2 参数进行预测的结果对比情况. 由图 5 可以看出, 在 12 月 20 日 05:00 LT 至 12 月 20 日 17:00 LT 期间, Dst 的大小范围处于 -100 nT 至 -30 nT 之间, 表明该时段发生了地磁暴, 在此期间三种方法的 f_0F_2 参数预测结果的相对误差相对于 12 月 20 日 05:00 LT 前未发生地磁暴时的相对误差均有增加, 表明了磁暴事件的发生对三种方法的预测结果都存在影响. 12 月 20 日 17:00 LT 至 2015 年 12 月 21 日 11:00 LT 期间, Dst 均小于 -100 nT, 表明该时段发生了大地磁暴, 相较于前两个时段, 该时段三种模型的预测相对误差再一次增加, 相对于平静期, 三种模型的平均相对误差分别增加了 1%~4%. 实验结果表明,




图 5 2015 年 12 月 19 日 15:00 LT 至 2015 年 12 月 21 日 14:00 LT 地磁暴期间 f_0F_2 参数预测结果

Fig. 5 Prediction results of f_0F_2 parameters during the geomagnetic storm period from 15:00 LT on 19 December 2015 to 14:00 LT on 21 December 2015




图6 2015年11月6日00:00 LT至2015年11月7日23:00 LT地磁暴期间 f_0F_2 参数预测结果

Fig. 6 Prediction results of f_0F_2 parameters during geomagnetic storms from 00:00 LT on 6 November 2015 to 23:00 LT on 7 November 2015

f_0F_2 参数的预测误差会随着地磁暴的发生和地磁暴级别的上升而增加。

图6给出了三种模型对测试集中2015年11月6日00:00 LT至2015年11月7日23:00 LT期间BOULDER探测站 f_0F_2 参数进行预测的结果对比情况。由图6可知,2015年11月7日03:00 LT后的 Dst 均小于 -30 nT,即发生了地磁暴事件。此地磁暴事件期间,LSTM模型预测结果的平均相对误差为16.21%,BiLSTM模型预测结果的平均相对误差为14.91%,BiLSTM结合相似特征法预测结果的平均相对误差为9.39%。对比三种方法的平均相对误差可知,BiLSTM结合相似特征法在地磁暴期间预测相对误差更小,预测精度更高,说明BiLSTM结合相似特征法能更好地减少地磁暴事件对 f_0F_2 参数预测结果产生的不利影响。

3 结论

提出了一种基于BiLSTM神经网络与电离层参数相似特征相结合的深度学习预测模型,用于预测电离层临界频率 f_0F_2 参数。为了验证本研究提出的预测模型对 f_0F_2 的预测能力及性能,构建了LSTM模型和BiLSTM模型与其进行比较和分析。模型的输入

为历史24 h的电离层临界频率 f_0F_2 参数,输出为未来24 h的 f_0F_2 参数。利用两个中纬度探测站以及一个低纬度探测站共三个站的2014—2015年的 f_0F_2 参数对模型分别进行训练并预测,将三种模型的预测结果与实测值进行了比较。结果表明,将BiLSTM网络与电离层参数相似特征相结合后,相较于LSTM模型,平均相对误差降低了6%~7%,而相较于BiLSTM模型,平均相对误差降低了4%~5%,由此可知BiLSTM结合相似特征法对 f_0F_2 参数预测准确度更高。此外,对不同纬度的探测站的预测结果分析发现,随着纬度的降低,预测精度也有所降低。不仅如此,本研究还对BOULDER探测站大地磁暴期间的 f_0F_2 参数的预测情况进行比较和分析,发现大地磁暴事件的发生对三种模型的预测结果都有较大的影响,相对于大地磁暴发生前后,三种模型的预测误差都有一定程度的增加。当地磁暴发生后,BiLSTM结合相似特征法能够更准确地预测 f_0F_2 参数,更好地减少地磁暴带来的干扰。虽然本研究提出的模型准确性较高,但是仍存在一定程度的预测偏差。由于日地参数对电离层临界频率 f_0F_2 参数有着不同程度的影响,因此未来可以考虑加入日地参数的相似度分析,且若能够获取更多探测站的数据,则可对该模型进一步改进。此外,可以探究电离层的其他参数,例如 h_mF_2 和TEC等参数

更优的预测方法, 发展其他神经网络模型, 实现更精准地预测电离层参数.

参考文献

- [1] BUONSANTO M J. Ionospheric storms — a review[J]. *Space Science Reviews*, 1999, **88**(3): 563-601
- [2] BILITZA D, REINISCH B W. International reference ionosphere 2007: improvements and new parameters[J]. *Advances in Space Research*, 2008, **42**(4): 599-609
- [3] BILITZA D, ALTADILL D, REINISCH B, *et al.* The international reference ionosphere: model update 2016[C]//EGU General Assembly 2016. Vienna: EGU, 2016: EGU2016-9671
- [4] COSPAR/URSI Working Group on IRI, BILITZA D. International reference ionosphere (1990)[J]. *Planetary and Space Science*, 1992, **40**(4): 544
- [5] STANISLAWSKA I, ZBYSZYNSKI Z. Forecasting of the ionospheric quiet and disturbed f_0F_2 values at a single location[J]. *Radio Science*, 2001, **36**(5): 1065-1071
- [6] CHAN A H Y, CANNON P S. Nonlinear forecasts of f_0F_2 : variation of model predictive accuracy over time[J]. *Annales Geophysicae*, 2002, **20**(7): 1031-1038
- [7] ZHANG Xiaohong, REN Xiaodong, WU Fengbo, *et al.* Short-term TEC prediction of ionosphere based on AR-IMA model[J]. *Acta Geodaetica et Cartographica Sinica*, 2014, **43**(2): 118-124 (张小红, 任晓东, 吴风波, 等. 自回归移动平均模型的电离层总电子含量短期预报[J]. *测绘学报*, 2014, **43**(2): 118-124)
- [8] 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)
- [9] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM[J]. *Neural Computation*, 2000, **12**(10): 2451-2471
- [10] MOON S, KIM Y H, KIM J H, *et al.* Forecasting the ionospheric F_2 parameters over Jeju Station (33.43°N, 126.30°E) by using long short-term memory[J]. *Journal of the Korean Physical Society*, 2020, **77**(12): 1265-1273
- [11] 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
- [12] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series[C]//Proceedings of 2019 IEEE International Conference on Big Data. Los Angeles: IEEE, 2019: 3285-3292
- [13] HU A Q, ZHANG K F. Using bidirectional long short-term memory method for the height of F_2 peak forecasting from ionosonde measurements in the Australian region[J]. *Remote Sensing*, 2018, **10**(10): 1658
- [14] RAO T V, SRIDHAR M, RATNAM D V, *et al.* A bidirectional long short-term memory-based ionospheric f_0F_2 and h_mF_2 models for a single station in the low latitude region[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, **19**: 8005405
- [15] JU Ping, JIANG Wei, ZHAO Xiayang, *et al.* Ninety-six points short-term load forecasting-theory & applications[J]. *Automation of Electric Power Systems*, 2001, **25**(22): 32-36 (鞠平, 姜薇, 赵夏阳, 等. 96点短期负荷预测方法及其应用[J]. *电力系统自动化*, 2001, **25**(22): 32-36)
- [16] JIN Haifeng, XIONG Xingen, WU Yaowu. Short-term load forecasting based on analogous theory[J]. *Automation of Electric Power Systems*, 2001, **25**(23): 45-48 (金海峰, 熊信良, 吴耀武. 基于相似性原理的短期负荷预测方法[J]. *电力系统自动化*, 2001, **25**(23): 45-48)
- [17] FENG Jing, LIU Wen, FAN Junmei, *et al.* A new method for short-term ionospheric forecast[J]. *Equipment Environmental Engineering*, 2009, **6**(3): 15-20 (冯静, 柳文, 凡俊梅, 等. 一种电离层短期预报的新方法[J]. *装备环境工程*, 2009, **6**(3): 15-20)
- [18] LIU Wen, JIAO Peinan, FENG Jing, *et al.* Method of similar days for ionospheric parameter short-term forecasting[J]. *Chinese Journal of Radio Science*, 2010, **25**(2): 240-247 (柳文, 焦培南, 冯静, 等. 电离层参数的相似日短期预测方法[J]. *电波科学学报*, 2010, **25**(2): 240-247)
- [19] REINISCH B W, GALKIN I A. Global Ionospheric Radio Observatory (GIRO)[J]. *Earth, Planets and Space*, 2011, **63**(4): 377-381

作者简介



郑丹丹 女, 1999年生, 福建人, 湘潭大学自动化与电子信息学院硕士研究生, 主要研究电离层参数预测方法.

E-mail: dandanzhlo@foxmail.com



柳文 (通信作者) 男, 1973年生, 湖南汨罗人, 教授, 目前主要从事电波传播理论及其在雷达、通信、导航中的应用研究.

E-mail: l_wen9209@sina.com