

# 基于深度学习的电离层参数预测研究

冯蕴天<sup>1</sup>, 吴霞<sup>2</sup>, 许雄<sup>1</sup>, 张荣庆<sup>3</sup>

(1. 电子信息系统复杂电磁环境效应国家重点实验室, 河南 洛阳 471003;  
2. 同济大学电子与信息工程学院, 上海 201804; 3. 同济大学软件学院, 上海 201804)

**摘 要:** 对于电离层参数预测, 通过长短期记忆 (LSTM) 的预测神经网络建模实现电离层参数的短期和日均值预测。使用逐点预测和序列预测 2 种方法, 并采用多维预测和经验模态分解 (EMD) 算法优化, 预测电离层参数的每小时和每天的变化规律。实验结果验证了所提优化算法在提高预测电离层参数预测精度上的可行性。

**关键词:** 长短期记忆; 电离层; 多维预测; 经验模态分解

**中图分类号:** TN92

**文献标识码:** A

**DOI:** 10.11959/j.issn.1000-436x.2021097

## Research on ionospheric parameters prediction based on deep learning

FENG Yuntian<sup>1</sup>, WU Xia<sup>2</sup>, XU Xiong<sup>1</sup>, ZHANG Rongqing<sup>3</sup>

1. State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics and Information System, Luoyang 471003, China

2. School of Electronics and Information Engineering, Tongji University, Shanghai 201804, China

3. School of Software Engineering, Tongji University, Shanghai 201804, China

**Abstract:** For ionospheric parameter prediction, the short-term and daily mean value prediction of ionospheric parameters was established by long short-term memory (LSTM) predictive neural network modeling. Two methods of point-by-point prediction and sequence prediction were utilized. Furthermore, in order to predict the hourly and daily changes of ionospheric parameters, the proposed scheme was optimized by multidimensional prediction and empirical mode decomposition (EMD) algorithm. Finally, the feasibility of the proposed optimization algorithm in improving the prediction accuracy of ionospheric parameters is verified.

**Keywords:** LSTM, ionosphere, multidimensional prediction, EMD

## 1 引言

传统的电磁态势演化预测采用纯电磁理论, 时间复杂度高, 并且不能实时获得计算数据。相比之下, 使用深度学习的电磁态势演化预测可以大大降低计算的复杂度和时间, 并且可以得到实时的仿真数据。因此, 使用深度学习建立电磁态势的预测模型具有重要意义<sup>[1]</sup>。

对电离层参数预测是电磁态势预测的重要组成部分。电离层环境变化对电子信息系统有着重要影响, 高频通信中, 准确预测电离层参数在无线通信的多个领域, 例如通信装备、航天器、雷达及导航装备的设计和运行维护都具有重要意义<sup>[2]</sup>。

为了改进传统纯电磁理论预测方式的缺点, 考虑到电离层的非线性属性, 国内外的学者提出了一些新的预测方法以期获得更精确的电磁态势预测模型<sup>[3-4]</sup>。

收稿日期: 2020-10-15; 修回日期: 2020-12-09

通信作者: 吴霞, wuxia@tongji.edu.cn

基金项目: 电子信息系统复杂电磁环境效应国家重点实验室课题基金资助项目 (No.CEMEE2020K0104B); 国家重点研发计划基金资助项目 (No.2017YFE0119300)

**Foundation Items:** The Open Research Fund of State Key Laboratory CEMEE (No.CEMEE2020K0104B), The National Key Research and Development Program of China (No.2017YFE0119300)

已有研究证明了人工神经网络在预测非线性的短波电离层参数上的优势<sup>[5]</sup>。针对反向传播 (BP, back propagation) 神经网络预测存在的梯度消失等问题, 长短期记忆 (LSTM, long short-term memory) 于 1997 年被提出<sup>[6]</sup>。在逐点预测电离层参数的短期变化中, LSTM 网络对于周期性最强的 F<sub>2</sub> 层临界频率 f<sub>0</sub>F<sub>2</sub> 的预测效果较好, 因此本文以 LSTM 为基础, 搭建神经网络模型实现电离层参数的短期和日均值变化预测, 并在 LSTM 网络结构中加入经验模态分解 (EMD, empirical mode decomposition) 算法。作为处理非线性信号的网络优化方法, EMD 算法已被广泛应用于深度学习中的数据处理<sup>[7]</sup>。文献[8-9] 分别在 BP 神经网络和小波神经网络中使用 EMD 算法进行地铁沉降监测和短期电力负荷预测, EMD 算法的引入减小了预测均方误差, 证明了 EMD 算法在提高神经网络预测精度上的可行性。

本文提出的电离层参数预测算法使用逐点预测和序列预测 2 种方法, 在使用多维预测的基础上, 又使用了在处理非线性数据上表现良好的 EMD 算法进行优化, 预测电离层参数的每小时和每天的变化规律, 并分析 EMD 算法和多维预测在提升预测精度上的优劣性。此外, 本文将 Adam 优化器作为网络的优化器<sup>[10]</sup>, 以期在不降低网络对短期变化的预测精度的条件下, 改善电离层参数的日均值预测, 使整个网络结构可以同时应用于电离层数据的短期和日均值变化预测。

## 2 LSTM 网络结构

LSTM 网络是一种特殊的循环神经网络 (RNN, recurrent neural network)。循环神经网络实质是把所有模块链式连接的递归神经网络, 以链式相连的重复模块称为循环单元。LSTM 网络循环单元如图 1 所示。

LSTM 网络内部有 4 个网络层, 其与传统的循环神经网络 (包含 3 个网络层, 即输入层、隐藏层和输出层) 最大不同之处就是在循环单元中增加了一个细胞状态 c<sub>t</sub>。细胞状态是 LSTM 网络的核心, 从图 1 可以看出, LSTM 网络通过 3 个门控制细胞状态, 分别是输入门、输出门、遗忘门。循环单元的输出 h<sub>t</sub> 不只取决于当前的输入和上一步的输出, 还取决于细胞上一步的状态。3 个门中最重要的是遗忘门, 其作用是当数据 x<sub>t</sub> 输入网络循环单元时决定是否丢弃上一步的循环单元状态 h<sub>t-1</sub>。遗忘门状态 f<sub>t</sub> 为

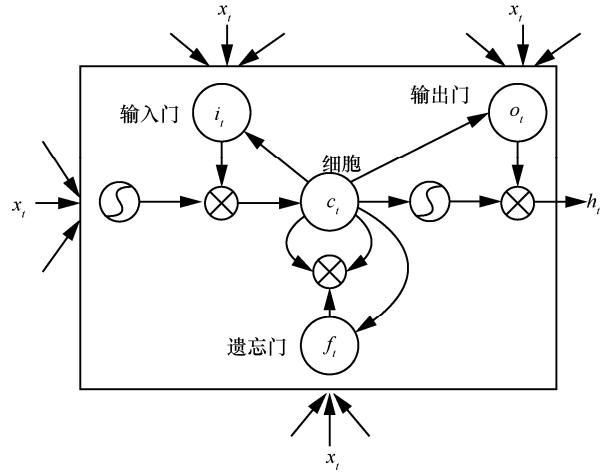


图 1 LSTM 网络循环单元

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (1)$$

其中,  $\sigma$  是 sigmoid 函数,  $b_f$  是遗忘门偏置项,  $c_{t-1}$  代表细胞的上一步状态;  $W_{xf}$ 、 $W_{hf}$ 、 $W_{cf}$  分别是遗忘门状态下  $x_t$ 、 $h_{t-1}$ 、 $c_{t-1}$  对应的权重矩阵 (后续计算式中  $W$  的含义同理), 矩阵中元素的数值为 0~1, 0 表示将数据全部丢弃, 1 表示全部保留。通过权重矩阵确定是否保留上一步的细胞状态, 以及上一步循环单元的输出状态与输入数据  $x_t$ 。确定需要丢弃的数据后, 将输入数据与隐藏层状态通过输入门得到输入门状态  $i_t$ 。输入门状态  $i_t$  为

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (2)$$

其中,  $b_i$  是输入门偏置项, 通过式(1)和式(2)得到输入门状态和遗忘门状态后, 就可以通过遗忘门状态丢弃一部分旧的细胞状态, 并通过输入门更新得到新的细胞状态。新的细胞状态  $c_t$  为

$$c_t = f_t c_{t-1} + i_t * \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3)$$

其中,  $b_c$  是细胞状态偏置项, \* 是卷积符号。通过式(2)和式(3)得到输入门状态和更新细胞状态后, 根据输入数据以及隐藏层上一步状态就可以得到新的循环单元输出状态  $h_t$ 。将细胞状态  $c_t$  与输入数据  $x_t$  通过输出门得到输出状态。输出门状态  $o_t$  为

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (4)$$

其中,  $o_t$  的作用是确定循环单元的输出状态。将细胞状态  $c_t$  经过一个 tanh 层得到一个 -1~1 的量值, 该量值与输出门相乘就可以得到该循环单元的最终输出  $h_t$ , 如式(5)所示。

$$h_t = o_t * \tanh(c_t) \quad (5)$$

### 3 电离层参数逐点预测

#### 3.1 数据预处理与模型训练

本文用于预测电离层短期变化的数据来自漠河电离层观测站 2014 年的观测数据。漠河电离层观测站的数据透明度高，并且观测准确度高，是合适的测试数据。这些观测数据包括 F<sub>2</sub> 层临界频率 f<sub>0</sub>F<sub>2</sub>、B<sub>1</sub> 参数、F<sub>2</sub> 层最低虚高 hpf、F<sub>2</sub> 层 3 000 km 传播因子 M(3000)F<sub>2</sub> 改变、F<sub>2</sub> 层最小反射频率 f<sub>min</sub> 等。从中选取质量较高的连续 1 400 h 的数据作为样本，将得到的数据样本分为训练集和测试集。取样本中 86% 的数据（共 1 200 h）作为训练集，剩下 200 h 的数据作为测试集。为了使网络更快收敛，首先将训练集数据采用 Minmaxscaler 方法进行归一化预处理；然后用预处理后的数据训练网络，用训练好的网络得到预测结果，通过对比测试集中的真实数据和预测结果分析预测效果。

训练网络时，将 24 h（即一天）的数据作为一个序列输入，使用 24 h 的数据预测后 1 h 的数据。经过多次实验调整，将网络的 batchsize 设置为 16，一次训练 16 个数据，网络一个周期迭代 75 次，共训练 3 个周期，即迭代 225 次。预测采用逐点预测，即每次只预测单一点，LSTM 网络中的序列本身是一个滑动窗口，窗口大小与序列长度相同，预测完一个点后，窗口移动到下一个测试数据，这样每次预测时都可使用完整的测试数据进行预测。例如，预测漠河电离层 F<sub>2</sub> 层临界频率时，如果要预测某时刻的数据，则将前面 24 h 的数据输入训练好的 LSTM 网络，依次类推，不断使用测试集的数据得到每一小时的预测结果。使用逐点预测方法预测电离层的不同参数，预测评价标准采用真实数据与预测数据之间的均方误差（MSE, mean-square error）。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y_0)^2 \quad (6)$$

其中，y<sub>i</sub> 表示真实数据，y<sub>0</sub> 表示预测数据。

在 LSTM 网络的基础上使用优化器 Adam。为了防止训练过程中出现过拟合，本文在第一层和第三层神经网络后面加入 dropout 层，以 0.2 的概率随机断开输入的 LSTM 神经元，减少了神经元之间的共同适应性和相互依赖性，确保了模型在丢失个体的情况下依然能保持良好的稳健性，避免发生过拟合。

#### 3.2 EMD 算法与多维预测算例分析

本文在搭建的 LSTM 网络结构中加入 EMD 算

法，使用 Python 的经验模态分解工具箱 Pyhht 将预处理后的数据分解为多个本征模函数。将电离层数据分解为 9 个本征模函数，每个本征模函数训练 4 个周期，一个周期迭代 75 次，每个本征模函数共迭代 300 次，将 EMD 算法得到的预测结果与多维预测（prediction2）结果对比，如图 2 所示。通过比较预测数据波形与真实数据波形的误差以及均方误差可以看出，基于 EMD 算法的预测数据在 75 h 后偏离真实数据。




图 2 EMD 算法和多维预测的 f<sub>0</sub>F<sub>2</sub> 预测结果对比

基于 EMD 算法的电离层传输因子 M(3 000)F<sub>2</sub> 和最低虚高 hpf 与多维预测结果对比分别如图 3 和图 4 所示。显然，基于 EMD 算法的 M(3 000)F<sub>2</sub> 预测波形在幅度上比多维预测更接近真实数据。由于 M(3 000)F<sub>2</sub> 序列稳定性较差，使用 LSTM 预测或者多维预测得到的预测结果较差，通过 EMD 可以将数据进行平稳化处理，使预测效果大大提高。与 f<sub>min</sub> 参数预测结果相似，基于 EMD 算法的 hpf 在 60 h 后的预测数据比多维预测更接近真实数据，总体预测效果也更好。




图 3 EMD 算法和多维预测的 F<sub>2</sub> 层 M(3 000)F<sub>2</sub> 预测结果对比

根据实验结果可以看出，EMD 算法可以作为短期变化预测的优化方法，并且对于非平稳时间序

列的优化效果要好于多维预测。但对于本身具有周期性的数据，EMD 算法的作用有限。不同预测方法 MSE 比较如表 1 所示。与直接使用 LSTM 网络预测的均方误差相比，基于 EMD 算法的  $f_{min}$  预测比多维预测减少了 23%； $M(3\ 000)F_2$  的预测均方误差比多维预测减少了 18.8%；hpf 的预测均方误差比多维预测减少了 11.8%。

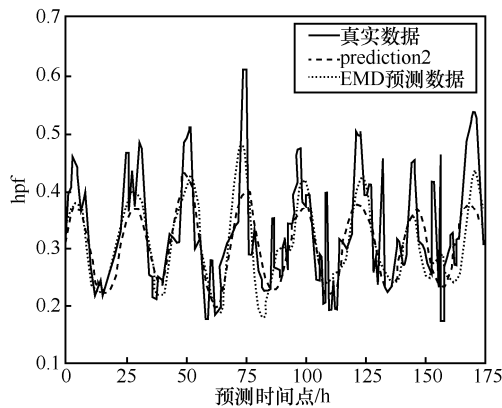


图 4 EMD 算法和多维预测的 hpf 短期变化预测结果对比

表 1 预测算法的 MSE 比较

| 预测方法    | $f_0F_2$ | $f_{min}$ | $M(3\ 000)F_2$ | hpf  |
|---------|----------|-----------|----------------|------|
| LSTM 网络 | 0.77     | 0.148     | 0.03           | 4.35 |
| 多维预测    | 0.74     | 0.13      | 0.025          | 2.95 |
| EMD 算法  | 0.75     | 0.1       | 0.020 3        | 2.6  |

### 4 电离层参数时间序列预测

LSTM 网络在电离层的短期变化和日均值变化预测中都能较好地匹配真实数据。但这种算法存在一定的局限性，因为每一个预测点在预测前都能得到真实数据，即使预测出现错误，算法也会直接使用真实数据来预测下一个点从而忽略这个错误。但在实际研究中有时需要直接预测一段时间内的电离层参数变化，这是逐点预测无法做到的。为此，本节首先采用全序列预测，通过训练好的神经网络一次性预测电离层参数在一段时间内的变化规律。全序列预测与逐点预测的不同之处在于，预测时采用上一时刻的预测数据而不是真实数据。通过预测 24 个数据点后，使用神经网络前 24h 的电离层数据预测下一时刻的数据，可以一次性预测电离层参数在未来多个小时内的变化趋势。电离层参数  $f_0F_2$  的全序列预测结果如图 5 所示。实验结果证明，电离层参数的短期变化的序

列预测可以和逐点预测一样通过 EMD 算法优化预测精度。




图 5  $f_0F_2$  短期变化全序列预测结果

### 5 结束语

本文以 LSTM 为基础，搭建神经网络模型以实现电离层参数的短期和日均值变化预测。通过预测结果分析了 LSTM 网络对不同类型的电离层参数的预测效果，并将这些结果作为对照组，分别使用多维预测和 EMD 算法对网络进行优化，验证多维预测和 EMD 算法在提高预测精度上的可行性。未来工作可以尝试在新的 LSTM 网络结构变式，例如门控循环单元 (GRU, gated recurrent unit) 和双向 LSTM (Bi-LSTM) 网络使用多维预测和 EMD 算法，降低网络的计算成本，并且不再局限于预测电离层数据，还包括预测经纬度、地磁指数、场强等电磁态势参数，进一步提高预测精度。

### 参考文献：

[1] 周侗. 海战场电磁态势生成若干关键技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2013.  
ZHOU T. Research on several key techniques of electromagnetic situation generation in sea battlefield[D]. Harbin: Harbin Engineering University, 2013.

[2] 高敬帆, 赵海生, 徐朝辉, 等. 拉萨地区电离层长期变化特性研究[J]. 电波科学学报, 2018, 33(6): 701-707.  
GAO J F, ZHAO H S, XU Z H, et al. Long-term ionospheric characteristics over Lhasa[J]. Chinese Journal of Radio Science, 2018, 33(6): 701-707.

[3] 张雯鹤, 黄国策, 董淑福, 等. 基于 LSTM 的短波频率参数预测[J]. 空军工程大学学报(自然科学版), 2019, 20(3): 59-64.  
ZHANG W H, HUANG G C, DONG S F, et al. A prediction of frequency parameters based on LSTM for high frequency communication[J]. Journal of Air Force Engineering University (Natural Science

Edition), 2019, 20(3): 59-64.

- [4] 孔庆颜, 柳文, 焦培南, 等. 电离层  $f_0F_2$  参数提前 24 小时预测[J]. 空间科学学报, 2009, 29(4): 377-382.  
KONG Q Y, LIU W, JIAO P N, et al. Twenty-four hour ahead prediction of  $f_0F_2$ [J]. Chinese Journal of Space Science, 2009, 29(4): 377-382.
- [5] HAJIHASSANI M, JAHED A D, MARTO A, et al. Ground vibration prediction in quarry blasting through an artificial neural network optimized by imperialist competitive algorithm[J]. Bulletin of Engineering Geology and the Environment, 2015, 74(3): 873-886.
- [6] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [7] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [8] 王昭斌, 胡伍生, 韩理想, 等. 基于经验模态分解和BP神经网络的地铁沉降预测模型研究[J]. 现代测绘, 2017, 40(5): 8-11.  
WANG Z B, HU W S, HAN L X, et al. The study of the deformation of subway based on the empirical mode decomposition and back propagation neural network[J]. Modern Surveying and Mapping, 2017, 40(5): 8-11.
- [9] 刘鑫. 基于机器学习的短期电力负荷预测方法研究[D]. 北京: 北京邮电大学, 2019.  
LIU X. Research on short-term load forecasting methods based on machine learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [10] DIEDERIK K, JIMMY B A. Adam: a method for stochastic optimization[J]. arXiv Preprint, arXiv:1412.6980, 2014.

### [作者简介]



冯蕴天 (1990- ), 男, 河南洛阳人, 电子信息系复杂电磁环境效应国家重点实验室工程师, 主要研究方向为电磁大数据和智能博弈推演。



吴霞 (1982- ), 女, 上海人, 博士, 同济大学副教授, 主要研究方向为计算电磁学、通信工程。



许雄 (1985- ), 男, 福建莆田人, 电子信息系复杂电磁环境效应国家重点实验室工程师, 主要研究方向为复杂电磁环境和体系对抗仿真。



张荣庆 (1985- ), 男, 河南洛阳人, 博士, 同济大学副教授, 主要研究方向为无线网络优化和人工智能。

## 收录声明

本刊对发表的文章,拥有出版电子版、网络版版权,并拥有和其他网站交换信息的权利。本刊支付的稿酬中已经包含上述费用。

*Journal on Communications* has the copyright to publish electronic edition, online edition of the published articles, and has the right to exchange information with other sites. The expenses have been included in the fee paid by editorial department.

## 道德声明

本刊发表的论文是作者独立取得的原创性研究成果,无一稿多投;论文内容不涉及国家机密;未曾以任何形式用任何文种在国内外公开发表过;论文内容不侵犯他人著作权和其他权利。若发生一稿多投、侵权、泄密等问题,论文作者将承担全部责任。

The authors of *Journal on Communications* guarantee that their submitted articles are original and contain nothing confidential. The said article is only submitted to *Journal on Communications*. The said article has not been published before and has not been submitted elsewhere for print or electronic publication consideration. The said article is no way whatever a violation or an infringement of any existing copyright or license from the third party. Otherwise, the authors of the said article shall take the blame for the violation or infringement of the related copyright and the leakage of secrets.

# 通信学报

Journal on Communications



发行代号：  
国内2-676  
国外M395

2021年4月25日出版 定价：98.00元

ISSN 1000-436X



9 771000 436212