

基于 LSTM 的短波频率参数预测

张雯鹤¹, 黄国策², 董淑福², 王董礼¹

(1. 空军工程大学研究生院, 西安, 710051; 2. 空军工程大学信息与导航学院, 西安, 710077)

摘要 针对现有短波通信频率参数预测方法操作繁琐、预测精度不足的缺点,首次提出一种基于长短期记忆型循环神经网络(LSTM RNN)的预测方法。通过对电离层参数 f0F2 数据的分析,利用 LSTM 在处理时序相关数据时可以长期记忆网络历史数据的优势,对 f0F2 值进行预测。对比反向传播神经网络(BPNN),LSTM 将误差降低了 7%,并将均方误差控制在 2% 以下。研究表明:基于 LSTM 搭建的提前预报 5 天的 f0F2 值的模型是可行的且比 BP 神经网络更适合预测电离层的 f0F2 值。

关键词 短波通信; 频率预测; 长短期记忆神经网络

DOI 10.3969/j.issn.1009-3516.2019.03.010

中图分类号 TN92 **文献标志码** A **文章编号** 1009-3516(2019)03-0059-06

A Prediction of Frequency Parameters Based on LSTM for High Frequency Communication

ZHANG Wenhe¹, HUANG Guoce², DONG Shufu², WANG Dongli¹

(1. Graduate College, Air Force Engineering University, Xi'an 710051, China;

2. Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: Aimed at the problems that in the existing high frequency communication, the frequency parameter prediction methods are tedious formalities in operation and shortage in precision, this paper presents a prediction model of frequency parameters of short-wave communication based on long short-term memory recurrent neural networks. This neural network can break through the limitations of traditional neural networks and establish long-term correlations on data sequences. The experimental results show that the mean square error (MSE) can be control below 2% and the model reduced the error by 7%. And this method is effective and superior to the traditional prediction method.

Key words: HF communication; frequency parameter prediction; long short-term memory recurrent neural networks

短波通信具有超视距、低成本、强抗毁性等性能优势,在恶劣自然条件下的移动通信保障中具有广泛的应用前景。由于短波信道的时变色散特性,其可用性和可靠性受短波频率变化的影响较大,因此

短波频率的选取至关重要。通过预测电离层参数能够为选择适当短波通信频率提供指导,进而调整短波系统参数以适应短波信道变化,因而能够提高短波通信质量。

收稿日期: 2018-09-01

基金项目: 国家自然科学基金(61701521)

作者简介: 张雯鹤(1995—),男,陕西西安人,硕士生,主要从事短波通信研究。E-mail:547855206@qq.com

引用格式: 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 Wenhe, HUANG Guoce, DONG Shufu, 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.

目前常用的频率预测方法分为长期预测和短期预测。长期预测是基于早期历史数据,建立数学模型,利用数学公式计算电离层参数,代表方法有国际电联 CCIR 早期推荐方法(340 报告)、ITU-RP. 533^[1]方法以及亚大预测方法^[1]等。基于这些方法,一些机构搭建模型利用软件 REC533、VOACAP 等预测软件对电离层参数进行预测^[2]。短期预测是基于近期的历史数据,采用取平均值等数学方法得到预测频率值。随着人工神经网络^[3-5]的发展,人工神经网络在预测非线性数据^[6]方面表现出良好的特性,因此研究学者借助人神经网络来预测非线性的短波电离层参数,取得了较好的效果。早期的方法是利用反向传播神经网络^[7-8]来预测 f0F2 月中值,依据 f0F2 月中值隔月变化的规律来进行预测,最小误差约为 0.3 MHz,存在较大改进空间;文献[9]提出了一种将混沌和神经网络相结合的方法预测短波通信频率参数,利用混沌方法重构相空间系统吸引子,用前向多层神经网络拟合吸引子上的全局整体映射,构成混合预测模型;文献[10]提出一种基于思维进化的小波神经网络和混沌理论相结合的预测方法,利用小波算法的平滑作用减少误差。文献[11]提出了一种结合相空间重构技术和模糊小波神经网络^[13-15]技术,并在数据预处理阶段采用奇异值分解对历史数据进行降噪处理,使得预测精度得到了很大提高。在文献[16]中,将不同时间的信道状态构建为非平稳隐马尔科夫模型,根据历史数据,利用贝叶斯推理方法^[17]进行预测。文献[18]提出一种利用神经模糊推理系统构建电离层参数预测模型的方法,利用自学习算法和遗传算法分别建立推理规则和调整模型参数。上述这些方法都有一定缺陷,处理数据十分复杂,应用的神经网络算法也不适合对时间序列^[19-20]进行预测,没有真正发挥出深度学习算法^[21-22]的优势,而且由于这些方法只考虑了 f0F2 的月规律值变化,对 f0F2 月中值在黎明、黄昏时较大的变化以及相邻几天间甚至前几个小时变化的规律没有涉及;同时,反向传播神经网络预测存在的局部极小化、收敛速度慢、存在梯度消失或爆炸等问题,都对最终的预测效果和精度造成干扰。

针对上述问题,本文通过改进算法,考虑序列数据之间的联系,避免反向传播时梯度消失,提出一种双层长短期记忆型(Long Short-Term Memory, LSTM)循环神经网络(Recurrent Neural Networks, RNN)预测电离层参数的方法。

1 搭建神经网络预测模型

近些年的研究早已证明了神经网络在预测时间上的优势。神经网络可分为有监督学习和无监督学习 2 种,前者关注对事物未知表现的预测,一般包括分类问题和回归问题,后者则倾向于对事物本身特性的分析。本文将 BP 神经网络模型作为对照参考模型,重点介绍本文提出用来预测电离层参数的双层 LSTM 预测模型。

1.1 BP 神经网络模型

BP 神经网络是按照误差反向传播算法训练的前馈神经网络,具有十分强的非线性映射能力且内部结构设置灵活,是目前应用最广泛的神经网络模型。BP 神经网络由输入层、隐藏层、输出层构成,通过信号前向传递和误差反向传播不断对网络权重和偏差进行修正,最后实现达到使网络模型输出值和预期输出值之间误差尽可能小的目的。BP 神经网络的核心是梯度下降算法,所以 BP 神经网络模型容易陷入局部最小值,且学习速度较慢。BP 神经网络的简单模型见图 1,图中隐藏层含有 3 个神经元。

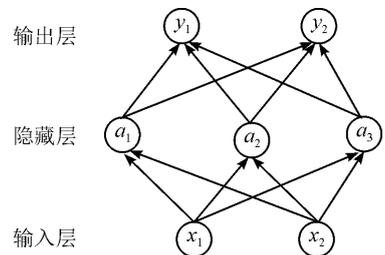


图 1 BP 算法模型结构

1.2 LSTM 模型

RNN 是目前应用广泛的人工神经网络模型,擅长处理序列数据。RNN 的基本结构由输入层、隐藏层和输出层 3 部分组成,其按时间序列展开结构如图 2 所示。与传统的神经网络不同,RNN 拥有“记忆性”,其隐藏层中的环路能够将历史信息向后传递,使当前时刻和历史信息紧密关联,利用这一特性,RNN 可以处理由任意时刻组成的输入序列。RNN 中的神经元通过神经元之间的权值 U 连接,从而构成环路,对一定长度的序列数据进行训练,预测输出。与传统神经网络不同的是,RNN 中的每一层都共享参数 W 、 U 、 V ,这样的设定减少了网络中需要学习的参数,只是每一步的输入不同。当输入新数据时,与来自 $t-1$ 时刻的信息经过运算成为当前时刻网络的输出,按照这个过程对每个数据样本进行处理。

RNN 的数学描述见式(1)、(2):

$$h_t = \varphi(Wx_t + Uh_{t-1}) \quad (1)$$

$$y_t = \text{softmax}(Vh_t) \quad (2)$$

式中: W 、 U 、 V 为权值参数; h_t 为隐藏层的第 t 步状态,它是网络的记忆单元; y_t 为第 t 步的输出; φ 为非线性激活函数,一般为 \tanh 函数。

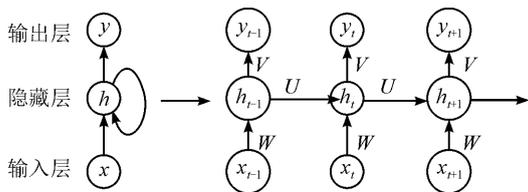


图 2 RNN 的结构模型

LSTM 的外部结构与传统的 RNN 结构相同,只对其隐藏层做了改进,具备了可以长期记忆历史信息的功能,如此,当梯度进行反向时间传播时,就不会出现梯度消失的问题,其隐藏层结构如图 3 所示。典型的 LSTM 网络由不同的单元或记忆块组成,上一个单元会输出记忆状态和隐藏状态到下个单元。记忆模块负责记忆各个隐藏状态或前面的序列数据特征,通过输入门、遗忘门、输出门来控制。

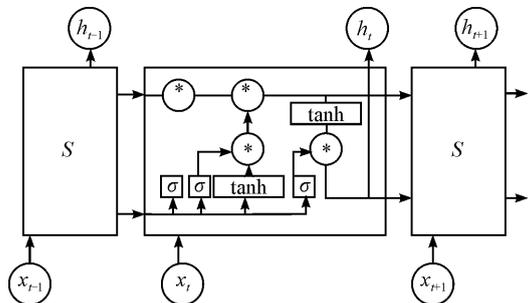


图 3 LSTM 隐藏层结构

在 t 时刻时,输入数据 x_t 以及之前时间步中传递下来的隐藏状态和记忆状态,经过门机制进行状态的更新,得到新的隐藏状态和记忆状态,并继续传递下去,如此,完成了长期记忆。具体的数学描述如下:

输入数据 x_t 和隐藏状态 h_{t-1} 经过输入门,得到状态 i_t ,表达式为:

$$i_t = \sigma(W^{(i)} x_t + U^{(i)} h_{t-1}) \quad (3)$$

输入数据 x_t 和隐藏状态 h_{t-1} 经过遗忘门,得到状态 f_t ,表达式为:

$$f_t = \sigma(W^{(f)} x_t + U^{(f)} h_{t-1}) \quad (4)$$

输入数据 x_t 和隐藏状态 h_{t-1} 经过输出门,得到状态 O_t ,表达式为:

$$O_t = \sigma(W^{(o)} x_t + U^{(o)} h_{t-1}) \quad (5)$$

于是得到 t 时刻的记忆状态 \bar{c}_t ,表达式为:

$$\bar{c}_t = \tanh(W^{(c)} x_t + U^{(c)} h_{t-1}) \quad (6)$$

最后得到最终的记忆状态 c_t 和最终的隐藏状态 h_t ,完成状态更新,输出与 RNN 结构相同。 c_t 和 h_t 表达式为:

$$c_t = f_t c_{t-1} + i_t \bar{c}_t \quad (7)$$

$$h_t = o_t \tanh(c_t) \quad (8)$$

通过这种算法,解决了传统神经网络训练时梯度消失或爆炸问题,实现了对序列数据关系的长期学习。

2 数据处理与模型训练

影响短波通信频率选择的主要因素是电离层参数的 f_0F_2 和 $M(3000)F_2$,其变化规律具有非线性特征。对此,利用实际观测的真实数据对网络进行训练,学习得到最优网络参数,确定预测模型。因此为验证本文所提模型的可用性与预测准确性,实验选用 2011 年 1 月北京真实测量的月中值 f_0F_2 作为测试数据,数据集共有连续测量的 775 h 的数据,如图 4 所示。由于不同纬度的电离层区域性明显有差异,故采用 2014 年 1 月海南三亚的电离层月中值 f_0F_2 数据作为样本数据集,如图 5 所示,共有连续测量的 775 h 的数据来检验 LSTM 电离层参数预测模型在不同地区的适用性。

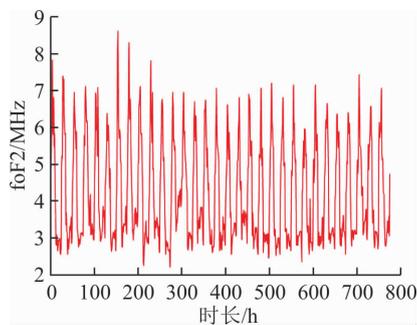


图 4 北京地区 2011 年 1 月 f_0F_2 观测值

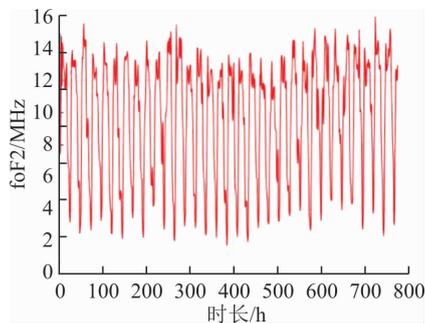


图 5 三亚地区 2011 年 1 月 f_0F_2 观测值

对电离层月中值 f_0F_2 数据进行预处理时,首先用对应时刻月平均值填补缺失的数据点,再对样本分为训练集和测试集。由于样本集共 775 h 的数据,取样本集的前 80% 共 620 h 的数据作为训练集,

取后 20% 共 155 h 数据作为测试集, 如表 1 所示。因为电离层月中值 f_0F_2 的变化幅度较大, 为便于神经网络学习和增强数据集的稳定性, 对数据进行归一化处理, 将其转化为 Numpy 数组供模型使用。对北京地区和三亚地区的数据集做相同处理。

表 1 训练及测试数据分配

数据地区	训练时长/h	测试时长/h
北京地区	620	155
三亚地区	620	155

LSTM 网络模型的训练过程和预测过程如图 6 所示。首先读取数据, 对数据预处理, 并将其分为测试集和训练集, 用训练集对模型进行训练, 训练好模型后, 就可以开始预测, 并将结果和测试集中的真实值比较, 分析预测效果, 根据预测效果来调整网络参数, 确定合适的网络模型参数用来做最后预测。

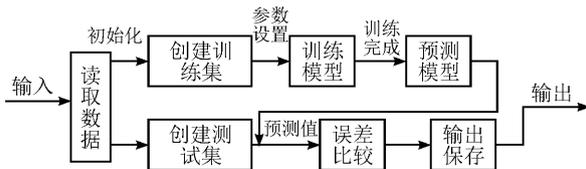


图 6 用 LSTM 网络搭建的模型

本文用双层 LSTM 网络来对电离层参数进行预测, 每层含有 128 个神经元, 隐藏层神经元的减少极大地缩短了训练时间。预测模型采用均方误差 (MSE) 作为损失函数、RMSprop 作为优化函数使模型尽快收敛。第 1 层 LSTM 输入维度设置为 1, 输出维度为 50, 第 2 层 LSTM 输入维度为 100, 2 层激活函数都为 tanh 函数, 并在每层后加入 Dropout 层, 防止数据过拟合, 最后, 用 Dense 全连接层完成线性输出一维预测结果。模型训练时, 每次输入 128 h 的数据, 将每 24 h 的数据作为 1 个小序列, 模型迭代次数为 400 代。模型训练完成后, 用训练好的模型预测未来月中值 f_0F_2 , 比较预测结果和测试集中的真实值, 检验模型准确度。

考虑到预测精度和模型训练时间的平衡, 经过多次试验调整, 采用 BP 算法预测模型的参数设定如下: 模型输入层的输出值的个数为 24 个, 隐含层为 4 层, 分别设置神经元数为 20 个、40 个、40 个、20 个, 输出层输出值为 1 个。隐含层的传递函数为正切 S 型传递函数, 输出层采用线性传递函数, 学习函数为 LM 变梯度算法, 采用 MSE 均方误差函数作为性能函数, 训练次数为 3 500 次, 学习速率为 0.01。同样利用北京的电离层参数 f_0F_2 数据进行训练, 每次用前 24 h 的数据去预测后 1 h 的数据。

3 评价标准与仿真结果分析

采用预测值与实际值之间的均方误差 (MSE) 和平均均方误差 (MMSE) 来描述预测的准确性, 即:

$$MSE = \frac{1}{N} \sum_{i=1}^N (observed_i - predicted_i)^2 \quad (9)$$

$$MMSE = \frac{1}{N} \sum_{i=1}^N \left(\frac{observed_i - predicted_i}{observed_i} \right) \quad (10)$$

为体现模型优势, 利用 LSTM 网络和 BP 神经网络同时对 f_0F_2 值进行预测。LSTM 神经网络预测北京和三亚地区的结果与真实测量值分别为图 7 和图 8 所示, 纵轴为预测样本的频率值, 单位为 MHz, 横轴是预测的时间点, 单位为 h。从预测结果图中可以看出模型良好的预测效果, 尤其是在前期的预测中精度很高, 几乎完全拟合, 在变化较快的位置, 也很好的预测了变化趋势。对其进行误差分析时, 可明显看出预测未来的时间越短, 预测数据与真实值的误差越小, 反之, 预测较远的时间, 相对误差越大, 预测值越不可信。同时, 模型预测不同纬度地区北京和三亚的电离层月中值 f_0F_2 精确度都比较高, 最大误差小于 5%, 因此模型用来预测不同区域的电离层参数是完全适用的。

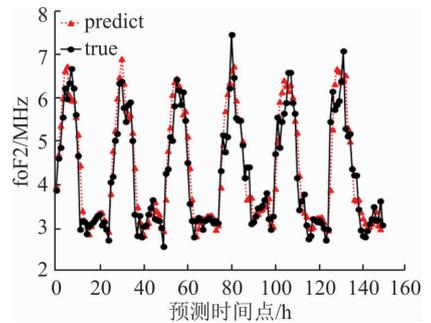


图 7 LSTM 网络模型预测北京地区结果

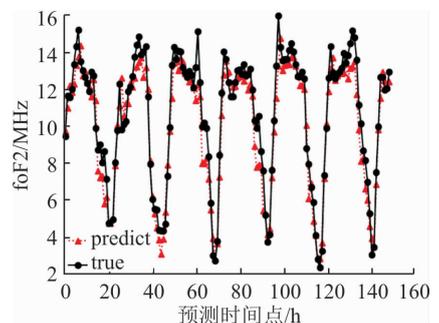


图 8 LSTM 网络模型预测三亚地区结果

BP 模型预测北京地区电离层的结果如图 9 所示, 可直观地看出虽然预测结果的趋势与真实趋势基本相同, 但其变化趋势明显超前, 预测结果偏于保

守,误差较大,平均误差大于 10%,预测效果远不如文中所提的 LSTM 电离层参数预测模型,且 BP 预测模型的稳定性较差,因为神经网络的随机性,训练得到的模型稳定性较差,需要多次调整训练才能得到合适的模型。

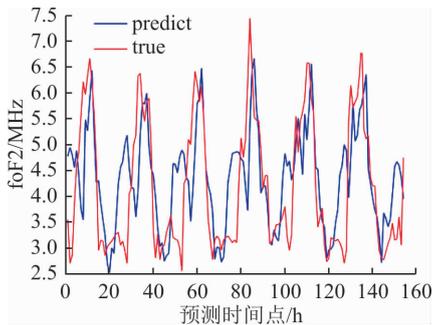


图9 BP网络模型预测北京地区结果

通过对比 2 种模型复杂度和预测结果发现,采用双层 LSTM 网络模型预测精度更高,且 LSTM 模型收敛速度更快,全局收敛性更好,在各个方面均优于 BP 模型,也优于同类预测算法。预测模型的性能参数比较见表 2。

表2 算法性能比较

算法	均方误差	平均均方误差	收敛性	收敛速度
BP	0.096	0.032	容易陷入局部极小值	训练 3 500 次
LSTM	0.012	0.006	全局收敛性良好	训练 400 次

4 结语

深度学习算法是人工神经网络领域的一大突破,通过组合低层特征形成更抽象的高层特征,从而发现数据的分布特征,其在各项数据预测中都表现出良好的预测效果。针对短波通信频率的预测问题,研究者给出了许多预测方法,文中提出利用 LSTM 网络搭建模型来预测电离层参数,利用北京 2011 年 1 月的 foF2 实测值数据进行训练并测试,实验结果验证了方法的可行性,且具有收敛速度快,收敛性好于其他神经网络,预测精度高的特点。相比于 BP 算法和其他预测电离层参数的算法有了较高的性能提升,为预测短波频率提供了新的精确度较高的方法。

由于导致电离层参数变化的因素很多,本文并未对其它因素进行总结探讨,利用 LSTM 模型仅预测验证了 foF2 月中值,后续工作还需加入更多影响短波频率的因素,利用更多的有效方法来减小预测值与实际值的误差,进一步提高模型的预测精度。

参考文献(References):

- [1] 李忠勤,孙宪儒. 亚大预测与 CCIR 推荐方法(340)报告的比较[J]. 电波科学学报,1992,7(2):17-29.
LI Z Q, SUN X R. YaDa Prediction Compared with CCIR Recommendation Method(340 Report) [J]. Chinese Journal of Radio Science, 1992, 7(2): 17-29. (in Chinese)
- [2] BARCLAY L, BEHM C, CARROLL S. Digitally Modulated HF Communications Reliability: Modifications to ITU-R Rec. P. 533 Propagation Model and the Associated Computer Program REC533 [C]//The Institution of Engineering and Technology, International Conference on Ionospheric Radio Systems and Techniques, Edinburgh, UK; [s. n.], 2009: 10661861.
- [3] LEUNG H, WANG S C. Prediction of Noisy Chaotic Time Series Using an Optimal Radial Basis Function Neural Network [J]. IEEE Transactions on Neural Networks, 2001, 12(5): 1163-1172.
- [4] NATH S, KOTAL S D, KUNDU P K. Seasonal Prediction of Tropical Cyclone Activity over the North Indian Ocean Using the Neural Network Model [J]. Atmosfera, 2015, 28(4): 271-281.
- [5] AZMAT F, CHEN Y, STOCKS N. Analysis of Spectrum Occupancy Using Machine Learning Algorithms [J]. IEEE Transaction Vehicular Technology, 2016, 65(9): 6853-6860.
- [6] HAJI HASSANI M, ARMAGHANI D J, 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): 1-5.
- [7] XUE J D, JI X Z, TAO K, et al. Prediction of Cement Filling Materials Performance Using Improved BP Neural Network [J]. Journal of Chemical & Pharmaceutical Research, 2014, 6(6): 1681.
- [8] 张想,李明齐,王潮. 基于 BP 神经网络的短波通信信道预测方法[J]. 工业控制计算机,2017,30(10):55-56,59.
ZHANG X, LI M Q, WANG C. A Prediction Method for HF Communication Channel Based on BP Neural Network [J]. Industrial Control Computer, 2017, 30(10): 55-56, 59. (in Chinese)
- [9] 简相超,郑君里. 混沌和神经网络相结合预测短波通信频率参数[J]. 清华大学学报(自然科学版),2001,41(1): 16-19.
JIAN X C, ZHANG J L. Prediction of Frequency Parameters in Short Wave Radio Communication Based on Chaos and Neural Networks [J]. Journal of Tsing-

- hua University (Science and Technology), 2001, 41 (1): 16-19. (in Chinese)
- [10] 赵德群, 陈鹏宇, 孙光民, 等. 基于 MEA-WNN 的短波通信最佳频率预测[J]. 北京工业大学学报, 2018, 44 (2): 215-219.
- ZHAO D Q, CHEN P G, SUN G M, et al. Prediction of Best Frequency Parameters of HF Communication Based on MEA-WNN [J]. Journal of Beijing University of Technology, 2018, 44(2): 215-219. (in Chinese)
- [11] 任淑婷, 郭黎利. 基于模糊小波神经网络的短波频率预测 [J]. 通信技术, 2011, 44(4): 37-39.
- REN S T, GUO L L. A Prediction Method for HF Radio Communications Frequency Based on FWNN [J]. Communication Technology, 2011, 44(4): 37-39. (in Chinese)
- [12] LAI J, WANG H, LIU X, et al. A Quantitative Prediction Method of Network Security Situation Based on Wavelet Neural Network[C]// The First International Symposium on Data, Privacy, and E-Commerce, 2007. New York: IEEE, 2007: 197-202.
- [13] VENKATA R R, KRISHNA B, KUMAR S, et al. Monthly Rainfall Prediction Using Wavelet Neural Network Analysis[J]. Water Resources Management, 2013, 27(10): 3697-3711.
- [14] LAI J B, WANG H Q, LIU X W, et al. A Quantitative Prediction Method of Network Security Situation Based on Wavelet Neural Network[C]// The First International Symposium on Data, Privacy and E-Commerce. Chengdu, China: IEEE, 2007: 197-202.
- [15] CHE G, LUH, P B, MICHEL L D, et al. Very Short-Term Load Forecasting: Wavelet Neural Networks with Data Pre-Filtering[J]. IEEE Transactions on Power Systems, 2013, 28(1): 30-41.
- [16] 王董礼, 曹鹏, 黄国策, 等. 基于隐马尔科夫模型的短波认知频率选择方法[J]. 计算机应用, 2016, 36 (5): 1179-1182.
- WANG D L, CAO P, HUANG G C. High Frequency Cognitive Frequency Selection Mechanism Based on Hidden Markov Model [J]. Computer Application, 2016, 36 (5): 1179-1182. (in Chinese)
- [17] XING X, JING T, HUO Y, et al. Channel Quality Prediction Based on Bayesian Inference in Cognitive Radio Networks[C]// Proc IEEE INFOCOM. Turin, Italy: IEEE, 2013: 1465-1473.
- [18] 宋恒, 左继章, 周红建. 基于进化 ANFIS 的短波通信频率参数预测 [J]. 电子与信息学报, 2006 (7): 1282-1286.
- SONG H, ZUO J Z, ZHOU H J. Prediction of Frequency Parameters of Short-Wave Communication Based on ANFIS Evolved [J]. Journal of Electronics & Information Technology, 2006 (7): 1282-1286. (in Chinese)
- [19] WANG J S, NING C X, CUI W H. Time Series Prediction of Bank Cash Flow Based on Grey Neural Network Algorithm[C]// 2015 International Conference on Estimation, Detection and Information Fusion (ICEDIF). Harbin, China: IEEE, 2015: 272-280.
- [20] WANG Z, SALOUS S. Spectrum Occupancy Statistics and Time Series Models for Cognitive Radio[J]. Journal of Signal Process Systems, 2011, 62(2): 145-155.
- [21] LI J, BU H, WU J. Sentiment-Aware Stock Market Prediction: A Deep Learning Method[C]// 2017 International Conference on Service Systems and Service Management. Dalian, China: IEEE, 2017: 1-6.
- [22] ZHANG C, PATRAS P, HADDADI H. Deep Learning in Mobile and Wireless Networking: A Survey [EB/OL]. <https://arxiv.org/abs/1803.04311>.

(编辑: 徐楠楠)