

## 应用于认知无线电频谱预测的小波神经网络模型

朱正国<sup>1</sup> 何明星<sup>2</sup> 柳荣其<sup>2</sup> 刘泽民<sup>1</sup>

(攀枝花学院数学与计算机学院 攀枝花 617000)<sup>1</sup> (西华大学计算机与软件工程学院 成都 610039)<sup>2</sup>

**摘要** 精确的频谱预测能够有效地降低认知无线电系统的能耗,还有助于提高认知无线电系统的吞吐量。针对频谱预测方法的预测精度问题,提出了一种小波神经网络频谱预测模型,以预测通道占用状态情况。该模型利用离散小波变换产生分析信号的时频分布,使用一个时间序列来表示某子信道的占用状态;对预测精度、利用率和参数初始化之间的权衡进行了分析,以便选择一个近于最优的模型。实验测量结果表明,与基于BP神经网络算法的模型相比,所提模型在预测精度和能耗方面均表现出较优的性能。

**关键词** 认知无线电,频谱预测,小波神经网络,模型,预测精度,小波基函数

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.12.017

### Wavelet Neural Network Model for Cognitive Radio Spectrum Prediction

ZHU Zheng-guo<sup>1</sup> HE Ming-xing<sup>2</sup> LIU Rong-qi<sup>2</sup> LIU Ze-min<sup>1</sup>

(School of Mathematics and Computer Science, Panzhihua University, Panzhihua 617000, China)<sup>1</sup>

(School of Computer and Software Engineering, Xihua University, Chengdu 610039, China)<sup>2</sup>

**Abstract** Accurate spectrum prediction can effectively reduce the energy consumption of cognitive radio system and improve the throughput of cognitive radio system. In order to solve the problem of the prediction accuracy of spectrum prediction method, a wavelet neural network model was proposed to predict the state of channel occupancy. The discrete wavelet transform was used to generate the time-frequency distribution of the signal, and a time series was used to represent the state of a sub channel. The tradeoff between prediction accuracy, utilization and parameter initialization was analyzed to select a near optimal model. The experimental results show that, compared with the model based on BP neural network, the proposed model shows better performance in terms of prediction accuracy and energy consumption.

**Keywords** Cognitive radio, Spectrum prediction, Wavelet neural network, Model, Prediction accuracy, Wavelet basis function

认知无线电作为一种频谱共享技术,能够有效地利用空闲频谱来提高频谱利用率。在不影响合法授权用户通信的情况下,频谱预测越准确越好。现有的频谱预测主要分为自回归频谱预测、机器学习、神经网络(NN)频谱预测和马尔可夫模型频谱预测<sup>[1-2]</sup>。

在上述模型中,基于神经网络和基于马尔可夫的模型得到的结果都是较准确的<sup>[3-5]</sup>,但是它们较复杂,且需要很长的收敛时间,有效性受到限制。通过消除对参数设置和概率计算的需求,神经网络优于马尔可夫模型<sup>[6]</sup>。除了能够提高频谱效率和节约能源之外,与其他频谱预测方法不同,神经网络在预测之前就可以通过构建模型来满足预定的性能指标<sup>[7]</sup>。

文献[8]对基于频谱通道状态的常见频谱预测模型进行了总结。频谱通道状态用二进制向量表示:1表示繁忙的部

分,而0表示闲置的部分<sup>[9]</sup>。虽然该方法很简单,但是二进制的时序预测是基于硬判决的,忽略了有助于预测的有价值的信息,即测量的能源与阈值的接近程度。此外,阈值设置的误差有助于预测误差,因此本文采用软判决的频谱预测方法<sup>[10]</sup>。

小波变换可以较好地信号的局部表征进行时频分析,为建模提供了有用的信息。离散小波变换(DWT)用于将时间序列分解成子系列,记录了数据结构和周期性过程的详细信息。因此,本文提出了一种小波神经网络(WNN)频谱预测模型,并将其应用于认知无线电收发器。该模型利用离散小波变换产生分析信号的时频分布,使用一个时间序列来表示某子信道之前的占用状态,从而实现频谱预测。仿真结果表明,所提模型是一个复杂性较低、精确度较高的神经网络频谱预测模型。

到稿日期:2017-01-16 返修日期:2017-03-16 本文受国家自然科学基金(60773035),教育部科学技术重点项目(205136),四川省科技厅重点项目(05JY029-131)资助。

朱正国(1980—),男,硕士,讲师,主要研究方向为计算机网络、算法研究、小波神经网络, E-mail: 115824141@qq.com(通信作者);何明星(1964—),男,博士,教授,主要研究方向为现代密码算法、安全协议、无线网络安全技术;柳荣其(1971—),男,硕士,副教授,主要研究方向为大型数据库、GIS的应用、神经网络;刘泽民(1963—),男,硕士,教授,主要研究方向为机器智能、图形图像处理、神经网络算法。

### 1 提出的小波神经网络模型

基于小波基函数的小波神经网络的输出是数量有限的小波基函数的加权和<sup>[11]</sup>。神经网络权重的初始值是随机选择的,这通常会增加训练次数。小波的使用有助于优化初始权重、产生全局最小值并固定收敛速度。小波神经网络的理念是将小波基函数应用于数据训练<sup>[12]</sup>。此外,小波分析可以提供时间和频域局部相关结构,将小波表征方法与神经网络处理相结合可以提高后者的性能<sup>[7]</sup>。

本文提出的小波神经网络模型的基本结构如图 1 所示。




图 1 提出的小波神经网络模型的结构图

网络由  $n$  个隐藏层的神经元和  $m$  个外部输入连接构成。其中,  $\Psi$  表示小波,为通过变换与平移操作后由一个单独的函数  $\psi(x)$  生成的函数簇,其在文献[13]中可以表示为:

$$\Psi = \{ \Psi_j = \frac{1}{\sqrt{|a_j|}} \psi(\frac{x-b_j}{a_j}) : a_j, b_j \in R^n, j \in Z \} \quad (1)$$

其中,  $\psi(x)$  为母小波,它位于时间空间和频率空间中;向量  $a_j = \{ a_{j1}, a_{j2}, \dots, a_{jm} \}$  和  $b_j = \{ b_{j1}, b_{j2}, \dots, b_{jm} \}$  分别被命名为尺度参数和转换参数;  $x = \{ x_1, x_2, \dots, x_m \}$  表示小波神经网络的输入。

神经元  $j$  的网络内部活动在文献[14]中表示为:

$$v_j = \sum_{k=0}^m W_{jk} \cdot x_k \quad (2)$$

其中,  $W_{jk}$  表示输入  $k$  和隐藏节点  $j$  之间的权重。通过运用母小波  $\psi(v)$  来计算第  $j$  个神经元的输出。

母小波的选择取决于应用程序,墨西哥帽小波证实了它在不同的应用程序中的有用性。文献[15]将其表示为:

$$\psi(v) = (1-v^2) \cdot \exp(-\frac{v^2}{2}) \quad (3)$$

因此,第  $j$  个神经元的输出取决于:

$$\Psi_j = \frac{1}{\sqrt{|a_j|}} \psi(\frac{v_j - b_j}{a_j}) \quad (4)$$

显然,隐藏层第  $j$  个单元的定位取决于尺度(或频率)参数  $a_j$  和转换(或时间)参数  $b_j$ ,这两个参数可以通过基于小波变换理论预先确定,也可以取决于训练算法。 $a_j$  最简单的设置是 2 的整数幂,而  $b_j$  被设置为  $a_j$  的整数倍。也可以根据文献[15]给出的实际输入来初始化小波的变换与平移参数:

$$a_k = 0.2(x_{\max} - x_{\min}) \quad (5)$$

$$b_k = 0.5(x_{\max} + x_{\min}) \quad (6)$$

其中,  $x_{\max}$ ,  $x_{\min}$  分别表示最大输入值和最小输入值。

在小波神经网络的标准形式中,输出表示为:

$$f(x) = \sum_{j=1}^n W_j \Psi_j(v) \quad (7)$$

其中,  $W_j$  表示第  $j$  个神经元和输出节点之间的权重。

### 2 频谱预测算法

本文中小波神经网络训练方法运用了反向传播(BP),其

目的是找到造成误差  $e$  的每个权重的百分比,通过先平方再除以 2 可得成对误差  $E$  的数值。应用最陡下降法对时间  $t$  产生的瞬时成对误差进行最小化,文献[14]中的表示如下:

$$E(t) = \frac{1}{2} e^2(t) = \frac{1}{2} (f(t) - d(t))^2 \quad (8)$$

其中,  $f$  和  $d$  分别表示模型和目标输出。

对网络进行训练,直至找到网络参数权重  $w = (a_k, b_k, W_{jk}, W_j)$  的完整矢量,完整矢量可以最小化误差函数。运用迭代方法处理一个大小为  $N$  的训练样本。在每次迭代  $t$  时计算权重向量的成对误差导数,然后根据文献[15]对权重向量进行更新:

$$\Delta w(t+1) = -\eta \cdot \frac{\delta E(t)}{\delta w} + \mu \cdot \Delta w(t) \quad (9)$$

其中,  $\eta$  表示学习速率,  $\mu$  表示常数动量项,常数动量项可以提高训练的速度,且能避免在更新权重时产生振动。

在权重向量中,基于相应误差函数的偏导数,对不同的参数进行更新,因此:

$$\Delta W_{jk}(t+1) = -\eta \cdot \frac{\delta E(t)}{\delta W_{jk}} + \mu \cdot \Delta W_{jk}(t) \quad (10)$$

$$\frac{\delta E(t)}{\delta W_{jk}} = e(t) \cdot \frac{\delta f(t)}{\delta W_{jk}} \quad (11)$$

然后得:

$$\Delta W_{jk}(t+1) = -\eta \cdot e(t) \cdot W_j \cdot \Psi_j(x_k(t)) \cdot \frac{x_k(t)}{a_k(t)} + \mu \cdot \Delta W_{jk}(t) \quad (12)$$

根据式(13)对隐藏节点和输出节点之间的权重  $W_j$  进行更新:

$$\Delta W_j(t+1) = -\eta \cdot \frac{\delta E(t)}{\delta W_j} + \mu \cdot \Delta W_j(t) \quad (13)$$

其中:

$$\frac{\delta E(t)}{\delta W_j} = e(t) \cdot \frac{\delta f(t)}{\delta W_j} = e(t) \cdot \Psi_j(v_j(t)) \quad (14)$$

因此:

$$\Delta W_j(t+1) = -\eta \cdot e(t) \cdot \Psi_j(v_j(t)) + \mu \cdot \Delta W_j(t) \quad (15)$$

膨胀系数  $a_j$  的更新公式如下:

$$\Delta a_j(t+1) = -\eta \cdot \frac{\delta E(t)}{\delta a_j} + \mu \cdot \Delta a_j(t) \quad (16)$$

转换系数  $b_j$  的更新公式如下:

$$\Delta b_j(t+1) = -\eta \cdot \frac{\delta E(t)}{\delta b_j} + \mu \cdot \Delta b_j(t) \quad (17)$$

对图 1 所示的小波神经网络模型进行仿真实现,具体算法步骤如下:

- 1) 迭代设置  $m$  或  $n$  的数值;
- 2) 在 0 和 1 之间随机初始化  $W_{jk}$  和  $W_j$ ;
- 3) 初始化  $a_j$  和  $b_j$ ;
- 4) 用  $m$  个输入和  $n$  个隐藏节点构造 WNN;
- 5) 运用式(2)、式(4)、式(7)来计算预测输出值;
- 6) 运用式(8)来计算预测误差;
- 7) 若预测误差小于要求值,则停止迭代,否则运用式(12)、式(15)一式(17)更新权重。

其中,隐藏节点表示图 1 体现的构造中隐藏层的神经元。当误差  $e$  达到预先确定的阈值或者达到迭代的最大数量时,

停止学习。在仿真模拟中,将误差阈值设置为  $10^{-5}$ ,将迭代的最大数量设置为  $10^3$ 。

### 3 频谱预测仿真实验

#### 3.1 实验装置

为了验证提出的预测模型,在 100~200MHz 的频率范围内使用随机选择的载波频率进行调制,使用 ADVANTEST R4136 频谱分析仪对频率范围内接收到的功率进行测量。通常每隔一分钟使用通用接口总线将频谱分析仪的读数存储在一台电脑上,将前 1000 个数据作为训练样本,将后 10000 个数据作为测试样本。

#### 3.2 预测性能仿真

利用 Matlab R2014a 软件对图 1 所示的小波神经网络模型进行模拟;从上节实验装置提及的储存测量值中形成训练数据  $Y$ 。应用大小为  $m$  的滑动窗口从  $Y$  中选取  $m$  个连续的样本作为小波神经网络的输入,将第  $m+1$  个样本设置为期望的输出值  $dp$ 。将本文提出的新方法 with 文献[16]提出的基于 BP 神经网络方法进行性能比较。

本文采用错误预测概率来表示预测器的性能,其定义如下:

$$P_p = (T - \tau)^{-1} \left[ \sum_{t=\tau}^{T-1} (y_{t+1} = -1 | x_{t+1} = 1) + \sum_{t=\tau}^{T-1} (y_{t+1} = 1 | x_{t+1} = -1) \right] \quad (18)$$

其中,  $x_t$  和  $y_t$  分别为训练样本集的输入变量和输出值。在预测模型训练中,将整个序列分解成  $T-\tau$  个长度为  $\tau$  的向量。

为了验证不同通信场景下的预测性能,对授权用户的平均到达间隔时间  $t_{inter}$  和通信强度进行了修改。通信强度的计算公式为:

$$\rho = \frac{\text{mean ON time}}{\text{mean ON+OFF time}} = \frac{t_{serv}}{t_{inter}} \quad (19)$$

其中,  $t_{serv}$  为授权用户占用信道的平均时间,  $t_{inter}$  为授权用户到达的平均时间间隔。

#### 3.3 频谱预测精度分析

当通信强度和授权用户的平均到达间隔时间保持不变时,不同通信强度下的错误预测概率如图 2 所示,其中的平均到达间隔时间分别为 10slot 和 20slot。从图 2 中可以看出,当通信强度不断增加时,两种方法的错误预测概率均不断下降。




图 2 当通信条件不变时两种方法的预测性能的对比结果

当通信强度保持在 50% 不变,而不同信道的占用时间变化时,两种方法的频谱预测性能结果如表 1 所列。从表 1 中

可以看出,随着授权用户占用信道的平均时间  $t_{serv}$  不断增加,两种方法的频谱预测错误概率均下降,但是本文提出的小波神经网络模型的错误预测概率明显低于基于 BP 神经网络的方法。随着授权用户占用信道的平均时间增加,信道状态跳变次数减少,因此所提模型的错误预测概率由 16.21% 降低到 8.33%。

表 1 不同信道占用时间下两种方法的预测性能对比

$t_{serv}$	小波神经网络的错误预测概率/%	BP 神经网络的错误预测概率/%
5	16.21	23.75
8	10.69	18.22
9	9.87	16.43
10	9.02	15.17
11	8.33	14.48

#### 3.4 频谱感知能耗分析

采用感知能耗的改善率来分析不同方法的频谱感知能耗性能。假设进行 1 次频谱感知需要 1 个能量单元(记为  $U$ ),则感知能耗的改善率为:

$$SE(\%) = \frac{SE_{sense} - SE_{predict}}{SE_{sense}} = \frac{P_{idle}}{N_{total}} \quad (20)$$

$$SE_{sense} = N_{total} \times U \quad (21)$$

$$SE_{predict} = SE_{sense} - P_{busy} \times U \quad (22)$$

其中,  $P_{busy}$  表示感知结果为占用的时隙,  $P_{idle}$  表示预测结果为空闲的时隙数,  $N_{total}$  表示感知观测周期内的所有时隙总数。当通信强度为 50% 时,在不同用户到达间隔的情况下,两种预测方法的能量改善率  $SE$  的对比结果如表 2 所列,其中时隙总数  $N_{total}$  为 1000slot。

表 2 不同用户到达间隔情况下两种方法的预测性能对比

$t_{inter}$	小波神经网络的 SE/%	BP 神经网络的 SE/%
10	49.71	45.21
16	46.88	41.42
18	47.31	42.01
20	48.67	42.87
22	49.47	43.21

从表 2 中可以看出,在相同的用户到达间隔条件下,所提小波神经网络模型的能耗改善率更高,即更好地降低了感知能耗。其原因在于,当用户到达间隔不变时,本文方法预测出的空闲时隙数更接近真实的时隙数,减少了占用状态的时隙误判,从而有效地降低了感知能耗。

#### 3.5 参数影响分析

为说明基于小波神经网络的频谱预测精度与模型参数之间的关系,设置通信强度为 50% 和平均到达间隔  $t_{inter} = 10$  slot,针对两项参数进行了 5 组样本的仿真实验。表 3 列出了  $a_j$  和  $b_j$  的初始化设置对小波神经网络性能的影响。

表 3  $a_j$  和  $b_j$  的初始化设置对预测精度的影响

$a_j$	$b_j$	错误预测概率 $P_p$ /%
$2^k$	$a$	15.28
$2^k$	$2a$	13.15
$2^k$	$3a$	10.68
$2^{k+1}$	$2a$	13.97
$2^{k+1}$	$3a$	11.28

其中,  $k = \lceil \log_2(v_{\max}) \rceil$ 。从表 3 可以看出, 当  $a_j$  固定不变, 且  $b_j$  以  $a_j$  整数倍的形式增加时, 小波神经网络的预测精度性能不断提高。但从实验结果中发现, 当  $b_j = 5a_j$  时, 错误预测概率比  $b_j = 5a_j$  时更高, 即预测精度开始下降。当  $b_j$  固定时, 小波神经网络的预测精度随  $a_j$  的增加而降低。因此, 在  $a_j = 2^k$  且  $b_j = 4$  时获得最佳性能。

**结束语** 本文提出了一种小波神经网络认知无线电频谱预测模型。该模型利用离散小波变换产生分析信号的时频分布, 使用一个时间序列来表示某子信道的占用状态。对预测精度、利用率和参数初始化之间的权衡进行了分析, 以便选择一个近于最优的模型。仿真结果表明, 相比于基于 BP 神经网络的预测方法, 提出的小波神经网络方法显著降低了频谱感知的能耗, 提高了频谱利用率, 预测精度较高。今后将尝试进一步探讨如何降低频谱感知的能耗并提高频谱利用率, 使模型在预测精度和能耗方面均表现出更好的性能。

### 参 考 文 献

- [1] LI H, XU X, WU B, et al. Multilayer feedforward neural network based efficient spectrum occupancy prediction scheme for Cognitive Radio system[J]. Journal of Computational Information Systems, 2014, 10(10): 4017-4028.
- [2] WANG Y, ZHANG Z, MA L, et al. SVM-based spectrum mobility prediction scheme in mobile cognitive radio networks[J]. The Scientific World Journal, 2014, 2014(2): 212-223.
- [3] YI L Z, LIU Z L, LONG X. Wind power prediction by neural network based on redundancy analysis of mutual information [J]. Journal of Xiangtan University (Natural Science), 2016, 38(2): 68-72. (in Chinese)  
易灵芝, 刘智磊, 龙辛. 基于互信息冗余性分析的神经网络风电功率预测[J]. 湘潭大学(自然科学学报), 2016, 38(2): 68-72.
- [4] DING H Q, YANG J W, ZHAO Z Y. Performance analysis of spectrum sensing in cognitive radio networks [J]. Computer Science, 2010, 37(3): 125-127. (in Chinese)  
丁汉清, 杨家玮, 赵志远. 认知无线网络中频谱感知性能分析 [J]. 计算机科学, 2010, 37(3): 125-127.
- [5] LU Y, LIN X. Application of neural network to short-term load forecasting [J]. Journal of Shenyang University of Technology, 2006, 28(1): 41-44. (in Chinese)  
卢芸, 林莘. 神经网络在短期电力负荷预测中的应用[J]. 沈阳工业大学学报, 2006, 28(1): 41-44.
- [6] CANAVITSAS A, SILVA M L D, GRIVET M, et al. Spectral Vacancies Prediction Method for Cognitive Radio Applications [J]. Journal of Microwaves Optoelectronics & Electromagnetic Applications, 2016, 15(1): 18-29.
- [7] LI H, CHENG X, LI K, et al. Robust Collaborative Spectrum Sensing Schemes for Cognitive Radio Networks [J]. IEEE Transactions on Parallel & Distributed Systems, 2014, 25(8): 2190-2200.
- [8] XING X, JING T, CHENG W, et al. Spectrum prediction in cognitive radio networks [J]. IEEE Wireless Communications, 2013, 20(2): 90-96.
- [9] IVRIGH S S, SADOUGH S M S. Spectrum Sensing for Cognitive Radio Systems Through Primary User Activity Prediction [J]. Radioengineering, 2012, 21(4): 1092-1100.
- [10] BAI S, ZHOU X, XU F. "Soft decision" spectrum prediction based on back-propagation neural networks [C] // International Conference on Computing, Management and Telecommunications (ComManTel). New York: IEEE Press, 2014: 128-133.
- [11] WU J R, HU J M, QIN J X. Prediction of spectrum based on K-RBF neural network in Cognitive radio [J]. TV Technology, 2014, 38(5): 105-108. (in Chinese)  
吴建斌, 胡津铭, 秦继新. 基于 K-RBF 神经网络的认知无线电频谱预测[J]. 电视技术, 2014, 38(5): 105-108.
- [12] WU D P, ZHAO Y, XIONG Y, et al. Alarm information relevance mining mechanism based on wavelet neural network [J]. Journal of Electronics and Information Technology, 2014, 36(10): 2379-2384. (in Chinese)  
吴大鹏, 赵莹, 熊余, 等. 基于小波神经网络的告警信息相关性挖掘策略[J]. 电子与信息学报, 2014, 36(10): 2379-2384.
- [13] CHEN Y, YANG B, DONG J. Time-series prediction using a local linear wavelet neural network [J]. Neurocomputing, 2006, 69(4): 449-465.
- [14] ZAINUDDIN Z, PAULINE O. Improved Wavelet Neural Networks and Its Applications in Function Approximation [J]. Encyclopedia of Information Science & Technology Third Edition, 2015, 12(3): 6379-6396.
- [15] ALEXANDRIDIS A K, ZAPRANIS A D. Wavelet neural networks: A practical guide [J]. Neural Networks the Official Journal of the International Neural Network Society, 2013, 42(1): 1-27.
- [16] LI S R. Spectrum prediction of cognitive radio networks based on DE-BP [D]. Chengdu: Southwest Jiaotong University, 2013. (in Chinese)  
李书荣. 基于 DE-BP 的神经网络认知无线电频谱预测研究 [D]. 成都: 西南交通大学, 2013.
- [17] YU X. A Prediction Model for Wind Farms Power Generation Based on Fuzzy Neural Network [J]. Journal of Chongqing University of Technology (Natural Science), 2012, 26(9): 86-89. (in Chinese)  
喻晓. 基于模糊神经网络的风电功率预测[J]. 重庆理工大学学报(自然科学), 2012, 26(9): 86-89.