



基于二维 LMBP 神经网络的 ISM 频段预测算法

万晓榆, 胡盼, 王正强

(重庆邮电大学, 重庆 400065)

摘要:随着短距离无线通信技术的快速发展及应用,ISM(2.4 GHz)频段的电磁干扰问题日益凸现,而利用频谱预测来预先获知频段的占用信息,已成为解决设备间兼容共存问题的有效途径。在验证 ISM 频段时域频域相关性的基础上,提出了一种时频二维 LMBP 神经网络,并将其应用于 ISM 频段的频谱预测。通过仿真和理论分析得到了最佳的时频训练组合点($\Delta t=5$ 、 $\Delta f=2$),在神经网络输入向量 $N=9$ 的条件下,该点的预测准确度可达 95%,相比 Markov 算法和时域 LMBP 神经网络分别提高了 9% 和 4% 的预测精度,且具有更优的训练收敛时间。

关键词:ISM 频段时频相关性;BP 神经网络;时频二维 LMBP 神经网络;频谱预测精度

中图分类号:TN925

文献标识码:A

doi: 10.11959/j.issn.1000-0801.2016083

Spectrum prediction algorithm in ISM band based on two-dimensional LMBP neural network

WAN Xiaoyu, HU Pan, WANG Zhengqiang

Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract: With the rapid development and application of short-range wireless communications technology, the electromagnetic interference of ISM (2.4 GHz) band has become more apparent. Using the spectral prediction algorithm to predict the information of spectrum occupancy has become an effective way to solve the problem of compatible coexistence between devices. On the basis of verifying the time-domain and frequency-domain correlation of ISM band, an LMBP neural network of time and frequency domain was proposed and applied in the spectral prediction of ISM band. Through simulations and theoretical analysis, the best training combination of time-frequency point ($\Delta t=5$, $\Delta f=2$) was obtained. This point improves 95% of the spectrum prediction accuracy under the conditions of the input vector $N=9$ of the neural network. It increased 9% and 4% prediction accuracy compared with Markov algorithm and time-domain LMBP neural network and it had a better convergence time of training.

Key words: time-frequency correlation of ISM band, BP neural network, LMBP neural network of time and frequency domain, accuracy of the spectrum prediction

收稿日期:2015-12-08;修回日期:2016-02-04

基金项目:国家自然科学基金资助项目(No.11502039);重庆市基础与前沿研究计划基金资助项目(No.cstc2015jcyjA40004);工业和信息化部软科学项目(No.2012-R-51);重庆邮电大学博士科研启动基金资助项目(No.A2015-41);重庆邮电大学青年科学基金资助项目(No.A2015-62)

Foundation Items: The National Natural Science Foundation of China (No.11502039), The Basic and Advanced Research Project of Chongqing (No.cstc2015jcyjA40 004), The Soft Science Project of Ministry of Industry and Information (No.2012-R-51), Chongqing University of Posts and Telecommunications(No.A2015-41), The Science Research Project of Chongqing University of Posts and Telecommunications for Young Scholars (No.A2015-62)



1 引言

物联网产业的快速发展导致工作在 ISM 频段的物联网设备数量日渐增加,该频段的同频干扰问题日趋严重^[1,2]。由于 ISM 频段为非授权频段,小功率网络(如 ZigBee)极易被 WLAN(wireless local area networks,无线局域网)这类强功率设备的干扰所湮没,从而造成节点间的数据丢帧,甚至整个网络的瘫痪^[3]。

自 2006 年美国加利福尼亚大学 Acharya^[4,5]首次提出将预测机制应用到推演时域频谱空穴的出现时刻和持续时间后,各类预测算法在频谱预测中得到了广泛的应用^[6-8]。通过频谱预测算法来预先获知频段的占用信息,同样是解决 ISM 频段设备间兼容共存问题的一种有效途径。

参考文献[9]基于 GSM 频段的时域相关特性,采用一阶 Markov 链和时域 LMBP 神经网络来实现 GSM 频段的频谱预测,但该方法并未对频段的频域相关特性进行验证,且采用一阶 Markov 链和时域 LMBP 神经网络来实现 ISM 频段的频谱预测,算法的训练收敛时间和预测精度难以达到较为理想的均衡。参考文献[10]对 20 MHz~3 GHz 频段(包含 ISM 频段)的信道空闲数据和信道时频相关性进行了统计分析,并依此提出了基于频谱相关性的 2D FPM(frequent pattern mining)算法来实现信道预测,但该算法从频谱占用规律中挖掘出预测规则的最低训练时长为 2 h,否则难以保证预测精度和漏检率,因此该算法对于最低训练时长的限制不符合 ISM 频段信道时变性较大的特点。参考文献[11]针对现有 BP 神经网络预测算法的缺陷,在权重调整过程中,应用动量算法借鉴过往的累积经验,降低误差曲面改变引起的收敛振荡,并采用遗传算法搜索神经网络的最优权重和阈值,因此改进的 BP 神经网络具有更好的预测性能。但改进方法的最佳应用场景是在频谱占用率为 30%~70%时,否则预测性能并没有明显的提升,这不符合 ISM 频段 2.4 GHz 非授权频段的频谱占用规律。参考文献[12]提出了以时频二维联合的方式来发掘频谱的相关性,对 ISM 频段 2.4 GHz 的时频相关性进行了实测分析,并验证了提出的时频二维联合算法相比传统方法,在预测精度上具有更优的性能,但该方法并未考虑频谱预测中加入频域预测所增加的计算复杂度和预测时耗,通过增加预测成本来换取预测精度并不是最佳的途径,而找到时频二维预测矩阵的最佳组合点可以在不增加计算复杂度的前提下提高预测方法

的预测精度。

本文基于 ISM 频段的时频相关特性,提出了一种时频二维 LMBP 神经网络,构建时频二维预测矩阵,以相关性更强的频域输入来取代时域输入,可在保证预测精度的基础上,减少神经网络迭代训练的计算复杂度,进而缩短网络的训练收敛时间。仿真数据表明,同传统算法相比,时频二维 LMBP 神经网络在预测精度和训练收敛时间上性能更优,并确定了时频二维 LMBP 神经网络训练组合点($\Delta t=5$ 、 $\Delta f=2$)是实现 ISM 频段 2.4 GHz 频谱预测的最优组合点。

2 ISM 频段相关性的验证

验证 ISM 频段内部关联特性的实测工作是进行频谱预测的前提。要将频谱预测算法应用于 ISM 频段的频谱预测中,首先必须验证该频段呈现一定的相关特性。如果频段中各子信道的占用特性呈现随机性或低相关性,那么实现频谱预测将十分困难且毫无意义。

本文对 ISM 频段的频谱信息进行实际测量,频谱数据采集的参数设置见表 1。

表 1 实测参数设置

实测选项	参数值
实测仪器	Rohde & Schwarz fsl3 频谱分析仪
测量地点	重庆
测量时间	2015 年 2 月 7~13 日
频率范围/GHz	2.4~2.483 5
采样频点/个	110
采样间隔/min	5
天线半径/m	90

获得实测频谱数据后,本文采用了参考文献[13]提出的频谱数据量化处理方法,处理流程如图 1 所示。




图 1 实测数据量化处理流程

由图 1 可知,实测数据的量化式为:

$$CSI(t,c)=\begin{cases} 1, R(t,c) \geq \min\{R(i,c), i=1,2,\dots,T\}+3 \\ 0, \text{其他} \end{cases} \quad (1)$$

T_1, T_2 的相关度计算式为:

$$\rho_{T_1, T_2} = \frac{\sum_k I(T_1 = T_2) - \sum_k I(T_1 \neq T_2)}{\sum_k I(T_1 = T_2) + \sum_k I(T_1 \neq T_2)} \quad (2)$$

其中, $R(t,c)$ 和 $CSI(t,c)$ 分别表示时刻 T 下信道 C 的实测功率值和信道状态信息; $I(A)$ 为判别函数, 如 A 值为真, 则 $I(A)=1$, 否则 $I(A)=0$ 。

基于频谱使用规律和信道分配策略, 邻近时隙和邻近频点间的 CSI 值是否呈现一定的相关性对本文的频谱预测具有重要的价值, 因此本文分别对 ISM 频段的邻近时隙和邻近频点的相关性进行了验证, 相关性计算式如下所示。

邻近时隙:

$$R(\Delta t) = \frac{1}{T - \Delta t} \sum_{t=1}^{T-\Delta t} \rho_{CSI(t,:), CSI(t+\Delta t,:)} \quad (3)$$

邻近频点:

$$R(\Delta f) = \frac{1}{\Delta f} \sum_{f_1=1}^{\Delta f} \rho_{CSI(:, f), CSI(:, f+f_1)} + \frac{1}{\Delta f} \sum_{f_1=1}^{\Delta f} \rho_{CSI(:, f), CSI(:, f-f_1)} \quad (4)$$

以此得到邻近时隙和邻近频点的相关性曲线, 如图 2 所示。由图 2 可知, 临近时隙的相关性在 $\Delta t=5$ 前较高, 相关性呈线性递减趋势, 在 $\Delta t=5$ 后基本保持在 0.85 以




图 2 邻近时隙/频点的相关性曲线

下; 邻近频点的相关性在 $\Delta f=1$ 和 $\Delta f=2$ 时达到 0.85 以上, 之后随 Δf 的增加而递减。由此可以得到 2.4 GHz 频段相关性验证的结论: ISM 频谱具有短时的高度相关特性, 理论上论证了应用频谱预测算法的可行性; ISM 频段邻近频点间具有较强的相关特性, 尤其是 $\Delta f=1$ 和 $\Delta f=2$ 频点, 相关性明显高于 $\Delta t \geq 5$ 的时隙点, 后文将基于邻频点 ($\Delta f=1, \Delta f=2$) 的高度相关性, 提出对现有时域神经网络的改进。

3 时频二维 LMBP 神经网络

在各类预测算法中, BP 神经网络具有较强的模式分类能力, 对干扰数据具有较强的承受力, 使其成为近年预测算法应用的热点, BP 神经网络及神经元模型如图 3 所示。




图 3 BP 神经网络及神经元模型

传统 BP 神经网络的训练原理是通过时域训练序列的不断反馈, 以均方误差最小为目标来调整网络中的权值、阈值向量, 流程如图 4 所示。

结合前文 ISM 频段频谱相关性的结论可知, 该频段呈现多维相关的特点, 不仅具有时域上的高度相关性, 邻近




图 4 BP 神经网络训练原理



频点间(即频域)同样具有一定的相关性。因此本文提出以时域和频域结合的方法来建立二维 BP 神经网络。

如图 5 所示,在第一层网络中以并行的方式实现时域 $X_1=[CSI(t-1,c),CSI(t-2,c),\dots,CSI(t-n,c)]$ 和频域 $X_2=[CSI(t,c\pm 1),CSI(t,c\pm 2),\dots,CSI(t,c\pm n)]$ 的共同训练,得到第一层网络的输出向量 Y_{1i}, Y_{2i} ;在第二层网络中,将第一层训练得到的输出值 Y_{1i} 和 Y_{2i} 通过第二层网络的快速训练,得到最终的预测值 Y_i 。改进的神经网络一方面通过时频二维的输入向量提高频谱预测精度;另一方面采用时频训练并行的方式可以有效降低神经网络的计算复杂度,节省神经网络的训练收敛时间。图 6 是改进预测方法的二维坐标。

如图 6 所示,原有的预测方法通过时域上的虚点来预测目标点的值,必须采样大量的时域值来进行神经网络的训练,才能保证有效的预测精度;在时频二维预测方法中,将频域虚点加入输入向量中,构建二维预测矩阵,由于邻频点 ($\Delta f=1, \Delta f=2$) 的高度相关性,可在网络中减少时域

个数,有效提高神经网络的训练速度,在保证预测精度的基础上,减少神经网络的计算复杂度和训练收敛时间。

由于 ISM 频段的子信道最多有 16 个,即输出向量的行数最大为 16,考虑到 ZigBee 等底层设备低功耗的特点,本文采用训练收敛快速的 LM 算法^[14]来完成网络的训练。假设输出向量和目标向量分别为 $Y=[Y_1, Y_2, \dots, Y_m]^T, Z=[Z_1, Z_2, \dots, Z_m]^T$, 可得到误差函数为:

$$F(u) = \sum_{i=1}^m (Z_i - Y_i)^2 = \sum_{i=1}^m e_i^2 u = e^T(u) e(u) \\ = [e_1, e_2, e_3, \dots, e_m]^T \cdot [e_1, e_2, e_3, \dots, e_m] \quad (5)$$

其中, u 是由权值和阈值向量组成的神经网络参数向量,即:

$$u = [w_{11}^{(1)}, w_{12}^{(1)}, \dots, w_{nh}^{(1)}, b_1^{(1)}, \dots, b_h^{(1)}, \\ w_{11}^{(2)}, \dots, b_m^{(2)}, w_{11}^{(n)}, \dots, b_m^{(n)}] \quad (6)$$

参数向量 u 的牛顿法学习规则为:

$$u_{k+1} = u_k - H_k^{-1} g_k \quad (7)$$




图 5 时频二维 BP 神经网络




图 6 改进预测方法的二维坐标

其中, $\mathbf{H}_k^{-1}$ 为 Hessian 矩阵的逆矩阵, $\mathbf{g}_k$ 为 $F(\mathbf{u})$ 的梯度。

$$\mathbf{g}_k = \nabla F(\mathbf{u}) = 2\mathbf{J}^T \mathbf{u} \cdot \mathbf{e}(\mathbf{u}) \quad (8)$$

其中, $\mathbf{J}(\mathbf{u})$ 为 $\mathbf{e}(\mathbf{u})$ 的 Jacobian 矩阵, 即 $\mathbf{J}(\mathbf{u})$ 每一行分别为向量 $\mathbf{e}(\mathbf{u})$ 第 i 个分量对 $\mathbf{u}$ 中所有元素的偏导数。

$$\mathbf{J}(\mathbf{u}) = \begin{pmatrix} \frac{\partial e_1}{\partial w_{11}^{(1)}} & \frac{\partial e_1}{\partial w_{12}^{(1)}} & \dots & \frac{\partial e_1}{\partial w_{mm}^{(1)}} & \frac{\partial e_1}{\partial b^{(1)}} & \dots & \frac{\partial e_1}{\partial b_m^{(2)}} \\ \frac{\partial e_2}{\partial w_{11}^{(1)}} & \frac{\partial e_2}{\partial w_{12}^{(1)}} & \dots & \frac{\partial e_2}{\partial w_{mm}^{(1)}} & \frac{\partial e_2}{\partial b_1^{(1)}} & \dots & \frac{\partial e_2}{\partial b_m^{(2)}} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{\partial e_m}{\partial w_{11}^{(1)}} & \frac{\partial e_m}{\partial w_{12}^{(1)}} & \dots & \frac{\partial e_m}{\partial w_{mm}^{(1)}} & \frac{\partial e_m}{\partial b_1^{(1)}} & \dots & \frac{\partial e_m}{\partial b_m^{(2)}} \end{pmatrix} \quad (9)$$

由于 $F(\mathbf{u})$ 具有平方和误差的形式, 其 Hessian 矩阵可近似表示为:

$$\mathbf{H}_k = \nabla^2 F(\mathbf{u}) = 2\mathbf{J}^T \mathbf{u} \mathbf{J}(\mathbf{u}) \quad (10)$$

但考虑 $\nabla^2 F(\mathbf{u})$ 可能是半正定的, 即矩阵 $\mathbf{H}_k$ 可能为不可逆的, 所以在矩阵 $\mathbf{H}_k$ 中加入一个微增量 $\varphi_k \mathbf{I}$ 使其正定, 其中 $\varphi_k > 0$, $\mathbf{I}$ 为单位矩阵, 即:

$$\mathbf{N} = \mathbf{H}_k + \varphi_k \mathbf{I} \quad (11)$$

将式(11)、式(8)代入式(7)中, 可得到参数向量 $\mathbf{u}$ 的调整式:

$$\mathbf{u}_{k+1} = \mathbf{u}_k - \left[2\mathbf{J}^T(\mathbf{u}_k) \mathbf{J}(\mathbf{u}_k) + \varphi_k \mathbf{I} \right]^{-1} \cdot 2\mathbf{J}^T(\mathbf{u}_k) \cdot \mathbf{e}(\mathbf{u}_k) \quad (12)$$

当 $F(\mathbf{u})$ 达到预设的目标误差时停止训练, 得到最终的参数向量 $\mathbf{u}$, 完成神经网络的训练。

另外, 神经网络的训练复杂度和收敛速度也是网络性能的重要指标。LM 算法的计算复杂度^[15]为:

$$f(m) = O\left(\frac{m^3}{6}\right) \quad (13)$$

其中, m 为网络权值数目。神经网络中隐含层神经元数目的经验计算式为:

$$n = \sqrt{n_i + n_o} + S \quad (14)$$

其中, n_i 为输入神经元数目, n_o 为输出神经元数目, S 为 1~10 内的常数。由上文可知, n_o 为子信道数 16, 则式(14)可调整为:

$$n = \sqrt{n_i + 16} + 2 \quad (15)$$

由此, 神经网络中权值数目为:

$$m = (X+16)\left(\sqrt{X+16}+2\right) \quad (16)$$

其中, X 为神经网络的输入向量数目。

由此, 式(13)可调整为:

$$f(x) = O\left(\frac{\left[(X+16)\left(\sqrt{X+16}+2\right)\right]^3}{6}\right) \quad (17)$$

由复杂度的计算定理, 式(17)可化简为:

$$f(x) = O\left(X^{\frac{9}{2}}\right) \quad (18)$$

设时频二维 LMBP 神经网络的时域输入为 X , 频域输入为 Y , 则该时频二维 LMBP 网络的计算复杂度为:

$$f(x, y) = O\left(X^{\frac{9}{2}}\right) + O\left(Y^{\frac{9}{2}}\right) \quad (19)$$

而相同输入向量 $N(X+Y=N)$ 的时域 LMBP 神经网络的计算复杂度为:

$$f(N) = O\left(N^{\frac{9}{2}}\right) = O\left((X+Y)^{\frac{9}{2}}\right) \quad (20)$$

由式(19)、式(20)可知:

$$O\left((X+Y)^{\frac{9}{2}}\right) \geq O\left(X^{\frac{9}{2}}\right) + O\left(Y^{\frac{9}{2}}\right) \quad (21)$$

由此可得:

$$f(N) > f(x, y) \quad x, y \neq 0 \quad (22)$$

在相同输入向量条件下, 时频二维 LMBP 神经网络的计算复杂度低于时域 LMBP 神经网络的计算复杂度。由以上理论推导可知, 时频二维 LMBP 神经网络具有更优的训练复杂度。

4 仿真分析及结论验证

本文分别对传统时域 LMBP 神经网络和时频二维 LMBP 神经网络进行了网络的训练仿真和精度检验, 两者的 Δt 取值保持一致, 时频二维 LMBP 网络中加入频域输入向量。仿真中为了最大程度减少实测误差对预测精度的影响, 将前期实测的 ISM 频段频谱数据分为两部分, 前段实测数据作为神经网络的训练序列, 以得到神经网络的权值和阈值向量; 后段数据作为检验序列, 以验证神经网络的预测精度。

预测精度对比如图 7 所示。从图 7 可见, 时域 LMBP 神经网络的预测精度在 $\Delta t=5$ 之前呈递增趋势, 在 $\Delta t=5$ 之后基本稳定在 0.90 以下, 这表明时域 LMBP 神经网络的预测精度在 $\Delta t=5$ 时已趋于稳定, 增加过多的时域输入没有使预测精度有显著的提高, 反而会增加神经网络的训练复杂度和收敛时耗。

而在由 $\Delta f=1$ 、 $\Delta f=2$ 、 $\Delta f=3$ 构成的时频二维 LMBP 神





图7 LMBP神经网络预测精度对比

神经网络中,当 $\Delta t < 5$ 时,时频二维 LMBP 神经网络的预测精度较时域 LMBP 有较大的提高且保持递增的趋势;当 $\Delta t > 5$ 时,时频二维 LMBP 神经网络的预测精度趋于稳定,其中 $\Delta f=2$ 的预测精度最优,稳定在 95%左右。

此外,本文将 Markov 预测方法应用于 ISM 频段的频谱预测中,并将仿真结论与时域 LMBP 和时频二维 LMBP ($\Delta t=5$ 、 $\Delta f=2$)的预测精度进行比较分析。

输入向量数目 N 与预测精度对比如图 8 所示。由图 8 可见,时域 LMBP 神经网络和 Markov 算法的预测精度在 $N=5$ 之后稳定在 86%和 91%左右,即不能通过增加输入向量来提高预测精度;而时频二维 LMBP 神经网络($\Delta f=2$)的预测精度比时域 LMBP 算法提高 4%左右,比 Markov 算法提高 9%左右,且同样在 $N=9$ 之后趋于稳定。

图8 输入向量数目 N 与预测精度对比

另一方面,基于预测精度的结论,本文分别对 3 种方法在输入向量 $N=9$ 时的训练平均收敛时间进行了仿真对比,结论见表 2。由表 2 可知,时频二维 LMBP 神经网络在训练收敛时间上比另外两种方法更优,以误差目标为例,时频二维 LMBP 神经网络的训练收敛时间比时域 LMBP

快 1.9 倍,比 Markov 算法快 3.8 倍。

表2 算法平均训练收敛时间对比/s ($N=9$)

算法	误差目标				
	10^{-1}	10^{-2}	10^{-3}	10^{-4}	10^{-5}
时频二维 LMBP	1.67	5.17	19.87	57.34	126.98
时域 LMBP	3.61	9.87	28.17	75.36	253.17
Markov 算法	5.54	19.92	38.13	87.95	312.43

由以上仿真对比可知,时频二维 LMBP 神经网络相比时域 LMBP 神经网络和 Markov 算法在预测精度和训练收敛时间上均具有更好的性能,且时频二维 LMBP 神经网络以 $\Delta t=5$ 和 $\Delta f=2$ 作为输入向量,可实现在最低训练复杂度($N=9$)条件下,达到最优的 95%预测精度。

5 结束语

在 ISM 频段电磁干扰问题日益凸现的背景下,本文采用频谱预测算法来预测该频段的占用信息以解决设备间的兼容共存问题。在验证 ISM 频段时域频域相关性的基础上,提出了时频二维 LMBP 神经网络来实现 ISM 频段的频谱预测。仿真表明,在同样训练复杂度的条件($N=9$)下,时频二维 LMBP 神经网络相比 Markov 算法可提高 9%的频谱预测精度,相比传统时域 LMBP 神经网络可提高 4%的预测精度,且在不同误差目标下都具有更优的训练收敛时间,最后以此确定 ISM 频段的最优时频二维 LMBP 神经网络训练组合点($\Delta t=5$ 、 $\Delta f=2$)具有最低的计算复杂度和最佳的频谱预测精度。

本文基于 ISM 频段 2.4 GHz 的时频二维相关性,从频谱占用规律中挖掘出可行的时频二维预测方法。将该方法应用于 2.4 GHz 设备的频谱感知及信道选择中,以解决设备间的兼容共存,将是本文下一步的研究工作。

参考文献:

- [1] GUNGOR V C, HANCKE G P. Industrial wireless sensor networks: challenges, design principles and technical approaches [J]. IEEE Transactions on Industrial Electronics, 2009, 56(10): 4258-4265.
- [2] FIRDAU S, NUGROHO E, SAHRONI A. ZigBee and wifi network interface on wireless sensor networks [C]//2014 Makassar International Conference on Engineering and Informatics, November 26-30, 2014, Makassar, Indonesia. New Jersey: IEEE Press, 2014: 54-58.

- [3] XU R T, SHI G T, LUO J, et al. MuZi: multi-channel ZigBee networks for avoiding wifi interference [C]//2011 International Conference on Internet of Things and 4th International Conference on Cyber, Physical and Social Computing, October 19-22, 2011, Dalian, China. New Jersey: IEEE Press, 2011: 323-329.
- [4] MITOLA J, MAQUIRE G Q. Cognitive radios: making software radios more personal [J]. IEEE Transactions on Personal Communications, 1999, 6(4): 13-18.
- [5] XING X, JING T, CHENG W, et al. Spectrum prediction in cognitive radio networks [J]. IEEE Transactions on Wireless Communications, 2013, 20(2): 90-96.
- [6] HUANG P, LIU C J, YANG X, et al. Wireless spectrum occupancy prediction based on partial periodic pattern mining[J]. IEEE Transactions on Parallel and Distributed Systems, 2014, 25(7): 1925-1934.
- [7] 吴建绒, 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.
WU J R, HU J M, QIN J X. Prediction of spectrum based on K-RBF neural network in cognitive radio[J]. Video Engineering, 2014, 38(5): 105-108.
- [8] 张松. 基于马尔科夫链的 ZigBee 信道选择算法的研究[D]. 上海: 上海海洋大学, 2014.
ZHANG S. ZigBee channel selection algorithm research based on Markov chain [D]. Shanghai: Shanghai Ocean University, 2014.
- [9] 陈斌华. 认知无线电系统中的频谱预测算法研究 [D]. 北京: 北京邮电大学, 2011.
CHEN B H. Research on the spectrum prediction algorithm in cognitive radio system [D]. Beijing: Beijing University of Posts and Telecommunications, 2011.
- [10] CHEN D W, YIN S X, QIAN Z, et al. Mining spectrum usage data: a large-scale spectrum measurement study [J]. IEEE Transactions on Mobile Computing, 2012, 11(6): 1033-1046.
- [11] BAI S, ZHOU X, XU F J. "Soft decision" spectrum prediction based on improved-back-propagation neural networks [C]//2015 11th International Conference on Natural Computation, April 27-29, 2014, Zhangjiajie, China. New Jersey: IEEE Press, 2015: 128-133.
- [12] DING G, WANG J, WU Q, et al. Joint spectral-temporal spectrum prediction from incomplete historical observations[C]//2014 IEEE Global Conference on Signal and Information Processing, October 19-22, 2011, Atlanta, USA. New Jersey: IEEE Press, 2014: 1325-1329.
- [13] DAS D, DAS S. A survey on spectrum occupancy measurement for cognitive radio[J]. Wireless Personal Communications, 2015, 85(4): 2581-2598.
- [14] 习国泰. 改进 Levenberg-Marquardt 算法的复杂度分析 [D]. 上海: 上海交通大学, 2012.
XI G T. On the complexity of the modified Levenberg-Marquardt algorithm for nonlinear equations [D]. Shanghai: Shanghai Jiaotong University, 2012.
- [15] ZHOU G, JENNIE S. Advanced neural network training algorithm with reduced complexity based on Jacobian deficiency[J]. IEEE Transactions on Neural Networks, 1998, 9(3): 445-453.

[作者简介]



万晓榆(1963-),男,博士,重庆邮电大学教授、硕士生导师,主要研究方向为下一代网络技术、通信运营管理等。



胡盼(1990-),男,重庆邮电大学硕士生,主要研究方向为认知无线电、下一代网络技术。



王正强(1983-),男,博士,重庆邮电大学讲师,主要研究方向为认知无线电、5G 移动通信理论与关键技术、绿色通信等。