

## 基于 HS-BP 神经网络的认知无线电频谱预测技术

胡翩翩<sup>1</sup>, 曾碧卿<sup>2</sup>

(1. 华南师范大学 计算机学院, 广州 510631; 2. 华南师范大学 软件学院, 广东 佛山 528225)

**摘 要:** 在基于反向传播神经网络(BPNN)的频谱预测中,网络的初始权重与阈值是随机产生的,并且 BP 算法本身存在陷入局部最优的缺陷,从而导致 BPNN 训练得到的网络结构具有一定的不确定性。针对上述问题,提出一种基于 HS-BP 神经网络的频谱预测算法,通过和声搜索算法的全局寻优能力得到 BPNN 的最优初始权重和阈值,从而 BPNN 训练可得到最优的频谱预测网络结构,并运用该网络结构进行频谱的预测。仿真结果表明,该算法可以提高频谱预测的准确性及频谱的利用率。

**关键词:** 认知无线网络;反向传播神经网络;和声搜索算法;频谱预测;频谱感知;机器学习

**中文引用格式:**胡翩翩,曾碧卿. 基于 HS-BP 神经网络的认知无线电频谱预测技术[J]. 计算机工程,2017,43(7): 146-150,155.

**英文引用格式:**Hu Pianpian, Zeng Biqing. Cognitive Radio Spectrum Prediction Technology Based on HS-BP Neural Network[J]. Computer Engineering, 2017, 43(7): 146-150, 155.

## Cognitive Radio Spectrum Prediction Technology Based on HS-BP Neural Network

HU Pianpian<sup>1</sup>, ZENG Biqing<sup>2</sup>

(1. School of Computer, South China Normal University, Guangzhou 510631, China;

2. School of Software, South China Normal University, Foshan, Guangdong 528225, China)

**[Abstract]** Initial weight and threshold are random in the process of training Back Propagation Neural Network (BPNN). Moreover, BP algorithm is easy to fall into local optimum, so the training of BP neural network is uncertain to get the optimal network structure. To solve this problem, this paper proposes a spectrum prediction method of HS-BP neural network. Using the global optimization capability of harmony search algorithm, it can get the optimal initial weights and thresholds of the BP neural network, ensuring optimal BP neural network structure of training, ultimately, it can use the optimal BP neural network structure of training to predict the spectrum. Simulation results show that the algorithm can improve the accuracy of spectrum prediction and further improve the utilization of the spectrum.

**[Key words]** Cognitive Radio Network (CRN); Back Propagation Neural Network (BPNN); Harmony Search (HS) algorithm; spectrum prediction; spectrum sensing; machine learning

**DOI:**10.3969/j.issn.1000-3428.2017.07.024

### 0 概述

随着无线通信的迅猛发展,频谱资源变得日益紧张,提高频谱的利用效率也成为国内外学者研究的一项重要问题。认知无线电(Cognitive Radio, CR)作为一种提高频谱利用率的智能无线通信技术受到了广泛的关注<sup>[1-2]</sup>。认知无线网络(Cognitive Radio Network, CRN)允许次用户(Secondary User, SU)在不对主用户(Primary user, PU)造成干扰的情况下,动态地利用 PU 频谱资源,从而提高频谱的利

用率,因此,频谱感知成为 CRN 中的一项关键技术。

为了快速准确地感知 PU 信道状态,基于 BPNN 的频谱预测作为频谱感知中一种非常重要的方法,也被国内外学者进行了广泛的研究。文献[3]提出了 CRN 中基于 BPNN 的频谱预测模型,但 BP 算法存在容易陷入局部最优的缺陷,文献[4]提出了自适应的 BPNN 频谱预测模型,但仍没有考虑到 BP 算法本身的缺陷,文献[5]提出了基于 DE-BP 算法的频谱预测方法,通过差分进化(Differential Evolution, DE)算法有效地解决了 BP 算法的缺陷,但该算法的

**基金项目:**国家自然科学基金(71272144);国家自然科学基金青年基金(61503143)。

**作者简介:**胡翩翩(1991—),男,硕士研究生,主研方向为认知无线网络;曾碧卿,教授、博士。

**收稿日期:**2016-04-21 **修回日期:**2016-06-17 **E-mail:** zengbiqing0528@163.com

优化效果还有提升空间,文献[6]提出了使用粒子群(Particle Swarm,PS)算法来对 BP 神经网络进行优化,与 HS 算法一样,PS 算法也是一种启发式的全局优化算法,但是 PS 算法容易出现陷入局部最优、早熟收敛和停滞现象<sup>[7]</sup>。基于以上情况,本文提出基于 HS-BP 的神经网络频谱预测算法,在 CRN 的频谱预测中,通过使用 HS 算法来优化 BPNN 算法,并与 BPNN 算法和 DE-BP 算法进行对比。

## 1 基于 BPNN 的频谱预测

基于 BPNN 的频谱预测方法由文献[3]提出,与基于隐马尔可夫模型频谱预测方法<sup>[8]</sup>一样,是频谱预测中一项非常重要的方法。

### 1.1 基于 BPNN 的频谱预测模型

BPNN 包含有一个输入层、一个输出层和若干隐含层<sup>[9]</sup>。输入层包含有若干输入单元,其他层都包含有若干计算单元。除输入层外,每层的节点单元都有一个输入值  $I_j^l$  和输出值  $O_j^l$ :

$$I_j^l = \sum_i O_i^{l-1} w_{ij}^l + \theta_j^l \quad (1)$$

$$O_j^l = \frac{1 - \exp(-I_j^l)}{1 + \exp(-I_j^l)} \quad (2)$$

其中,  $I_j^l$  表示第  $l$  层第  $j$  个节点单元的输入值;  $O_j^l$  表示第  $l$  层第  $j$  个节点单元的输出值;  $w_{ij} \in [-1, 1]$  为相邻层之间的节点单元连接的权重;  $\theta_j^l$  为第  $l$  层第  $j$  个节点单元的阈值。

### 1.2 基于 BPNN 的频谱预测过程

信道的状态主要有 2 种:占用和空闲,可以使用 1 代表占用, -1 代表空闲,因此整个信道的状态可以用一个 1 和 -1 的序列表示。SU 对于频谱的预测主要分为以下 2 个步骤:

1) BP 神经网络训练。BP 神经网络通过将历史信道状态数据分为若干个目标输入集合和目标输出集合作为先验数据来进行网络的训练。整个训练过程由以下的 2 个部分组成<sup>[9]</sup>。

(1) 前向传输:对于第  $t$  个长度为  $\tau$  的目标输入集合  $X_t = \{x_t, x_{t+1}, \dots, x_{t+\tau-2}, x_{t+\tau-1}\}$ , 对应一个目标输出值为  $x_{t+\tau}$ 。使用式(1)和式(2)进行网络的前向传输,输出层的节点单元输出值表示为  $\bar{x}_{t+\tau}$ , 它是目标输出值  $x_{t+\tau}$  的预测值。

对于  $M$  组目标输入集合,均方差  $E$  为:

$$e_t = \bar{x}_{t+\tau} - x_{t+\tau} \quad (3)$$

$$E = \frac{1}{2} \sum e_t^2 \quad (4)$$

(2) 逆向反馈:为了提高预测准确性,需要尽可能地减少  $E$  的大小,所以需要动态调整网

络的权重  $w_i$  和阈值  $\theta_i$ 。

$$w_i = w_{i-1} + \Delta w_i \quad (5)$$

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} + \beta \Delta w_{i-1} \quad (6)$$

$$\theta_i = \theta_{i-1} + \Delta \theta_i \quad (7)$$

$$\Delta \theta_i = -\eta \frac{\partial E}{\partial \theta_i} + \beta \Delta \theta_{i-1} \quad (8)$$

2) 信道预测。训练得到最优的网络结构后,对于给定的目标输入集合就可以使用以下的公式进行频谱的预测。

$$\text{if } \bar{x}_{t+\tau} \geq 0 \text{ then } \bar{x}_{t+\tau} = 1 \quad (9)$$

$$\text{if } \bar{x}_{t+\tau} < 0 \text{ then } \bar{x}_{t+\tau} = -1 \quad (10)$$

## 2 基于 HS-BP 的神经网络频谱预测

由于基于 BPNN 的频谱预测中,BPNN 的初始权重和阈值是随机产生的,并且 BPNN 存在陷入局部最优的缺陷,本文提出使用 HS 算法<sup>[10]</sup>的全局寻优能力查找 BPNN 的最优初始权重和阈值,提高 BPNN 的预测准确性。

### 2.1 和声搜索算法的特点

HS 算法是一种启发式的全局搜索算法,虽然本身也存在陷入局部最优的缺点,但通过参数调优可以很大程度上提高算法的性能,通过 HS 算法的智能优化能力来获取 BPNN 算法的最优初始权重和阈值,从很大程度上克服了 BPNN 算法中使用随机权重和阈值的缺陷,另外相对于其他全局优化算法,HS 算法具有以下优势:

1) 算法简单,易于实现。

2) 约束条件较少,易于调优。

3) 使用和声记忆库以及随机搜索能力提高了搜索的灵活性,算法性能更好。

4) 在算法迭代过程中,对最优和声具有记忆能力,方便控制迭代次数。

### 2.2 和声记忆库编码的设计

解向量  $x_i$  的变量个数为 BPNN 的权重和阈值的总个数  $UNITNUM$ 。

$$UNITNUM = \sum_{i=1}^{n-1} nodes(i+1) \times (nodes(i) + 1) \quad (11)$$

其中,  $n$  为 BPNN 的层数。

利用 HS 对 BPNN 频谱预测模型进行训练,首先需要初始化和声记忆库,在初始化和声记忆库之前,需要建立 BPNN 连接权重和阈值与解向量之间的映射关系<sup>[11]</sup>。

$$\mathbf{x}_t = \{W_t^1, \Theta_t^1, \dots, W_t^{n-1}, \Theta_t^{n-1}\} \quad (12)$$

其中,  $t$  表示第  $t$  组解向量;  $n$  为 BPNN 的层数;  $W_t^k = \{w_{ij(t)}^k\}$ ,  $i$  为第  $k+1$  层的第  $i$  个节点,  $j$  表示第  $k$  层的第  $j$  的节点;  $\Theta_t^k = \{\theta_{i(t)}^{k+1}\}$ ,  $i$  表示第  $k+1$  层的第  $i$  个节点。

因此, 和声记忆库矩阵  $HM$  设计为:

$$HM = \begin{bmatrix} x^1 \\ x^2 \\ \vdots \\ x^{HMS} \end{bmatrix} = \begin{bmatrix} W_1^1 & \Theta_1^1 & \dots & W_{n-1}^1 & \Theta_{n-1}^1 & f(x^1) \\ W_1^2 & \Theta_1^2 & \dots & W_{n-1}^2 & \Theta_{n-1}^2 & f(x^2) \\ \vdots & \vdots & & \vdots & \vdots & \vdots \\ W_1^{HMS} & \Theta_1^{HMS} & \dots & W_{n-1}^{HMS} & \Theta_{n-1}^{HMS} & f(x^{HMS}) \end{bmatrix}$$

### 2.3 适应度函数

适应度函数是用来评价解向量  $\mathbf{x}_i$  优劣的函数, 通过和声搜索的不断进化和变异来寻找最优的解向量。

$$f(\mathbf{x}_i) = \frac{1}{N} \sum_{i=1}^N e_i^2 \quad (13)$$

其中,  $N$  为训练数据的组数;  $e_i$  为目标输出数据与预测数据的差值。

### 2.4 参数调优

在 HS 算法中, 首先需要初始化  $HMS$ ,  $HMCR$ ,  $PAR$ ,  $BW$  和  $MAXIMP$  这 5 个参数<sup>[12]</sup>。其中,  $HMCR$  和  $PAR$  这 2 个参数决定了全局寻解和局部寻解。 $PAR$  和  $BW$  是 2 个非常重要的参数, 主要是对解向量进行微调, 到达优化的效果, 并且决定了算法的收敛速度。在传统的 HS 算法中,  $PAR$  和  $BW$  这 2 个参数是固定的, 取值直接决定了整个算法的性能, 为了进一步提高算法效率, 本文对  $PAR$  和  $BW$  基于迭代次数进行动态自适应调整<sup>[13-14]</sup>。

$$PAR(gn) = PAR_{\min} + \frac{(PAR_{\max} - PAR_{\min})}{MAXIMP} \quad (14)$$

其中,  $PAR(gn)$  表示每次迭代微调概率;  $PAR_{\min}$  为默认最小微调概率;  $PAR_{\max}$  为默认最大微调概率;  $gn$  为当前迭代次数;  $MAXIMP$  为迭代总次数。

$$BW(gn) = BW_{\max} \times \exp(c \times gn) \quad (15)$$

$$c = \frac{\ln(\frac{BW_{\min}}{BW_{\max}})}{MAXIMP} \quad (16)$$

其中,  $BW(gn)$  表示每次迭代微调带宽;  $BW_{\min}$  为最小微调带宽;  $BW_{\max}$  为最大微调带宽。

### 2.5 算法实现流程与步骤

算法步骤如下:

1) 历史信道状态数据的产生。该数据用来 BPNN 的训练和预测。

2) 初始化 HS 算法中的  $HMS$ ,  $HMCR$ ,  $PAR_{\max}$ ,  $PAR_{\min}$ ,  $BW_{\max}$ ,  $BW_{\min}$  和  $MAXIMP$  参数。

3) 初始化和声记忆库  $HM$ 。

4) 产生一个  $rand(0,1)$  的随机数  $rand$ 。

5) 如果  $rand > HMCR$ , 在和声记忆库中选取和声, 否则在允许范围内随机产生新和声。

6) 如果  $rand > HMCR$ , 并且在和声记忆库中选取了和声  $\mathbf{x}_i$ , 则以  $PAR(gn)$  的概率对和声进行变异, 得到新和声, 并对其进行边界检查, 使其在允许范围内。

7) 得到一组新和声, 如果得到的新和声比  $HM$  中最差的和声要好, 则替换掉该和声。

8) 如果当前的迭代次数大于  $MAXIMP$ , 则终止算法, 否则, 重复执行步骤 4) ~ 步骤 8)。

9) 最终  $HM$  中最好的和声就是算法的最优解, 使用式 (12) 的映射方法将最优解映射到 BPNN 中, 得到 BPNN 各层初始化权值和阈值, 并对 BPNN 进行初始化。

10) 进行 BPNN 的训练和频谱预测。

算法流程如图 1 所示。

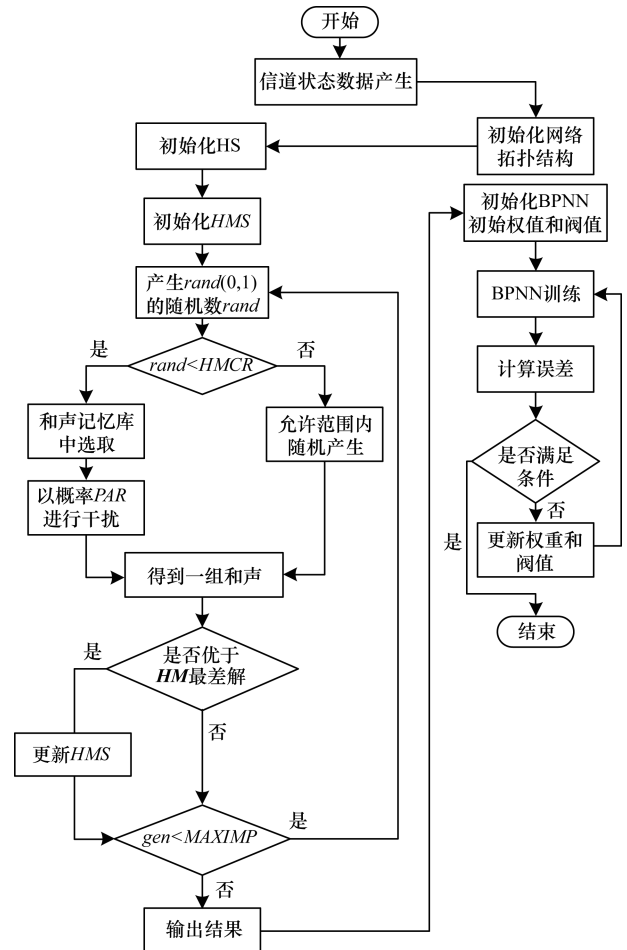


图 1 本文算法流程

### 3 仿真实验结果与分析

为了验证本文算法的有效性,在 Matlab R2010b 上进行相关的仿真实验。

#### 3.1 初始化工作

实验的初始化工作如下:

1) 信道状态数据的产生。本文采用 M/Geo/1 的排队模型<sup>[15-16]</sup>来产生信道状态数据作为仿真实验数据,另外,为了得到不同通信场景的 PU 用户的信道状态,本文通过改变通信强度  $\rho$  和 PU 的平均到达时间  $t_{\text{inter}}$  来实现<sup>[3,5]</sup>。

$$\rho = \frac{\text{mean ON time}}{\text{mean ON} + \text{OFF time}} = \frac{t_{\text{serv}}}{t_{\text{inter}}} \quad (17)$$

其中,  $t_{\text{serv}}$  为 PU 平均占用信道的时间;  $t_{\text{inter}}$  为 PU 平均到达时间间隔。

2) BPNN 预测模型的构建。本文采用的 BPNN 的结构为 4-15-20-1,即输入层有 4 个神经元与 2 个隐含层,神经元个数分别为 15 和 20,输出层有 1 个神经元,网络的训练次数设置为 50 次,BPNN 学习速率设置为 0.2,动量因子设置为 0.9,转换函数为 tansig,训练函数为 traingdm。

3) HS 算法参数的初始化。本文 HS 中的 HMS 设置为 10, HMCR 设置为 0.9,  $PAR_{\text{max}}$  设置为 0.5,  $PAR_{\text{min}}$  设置为 0.3,  $BW_{\text{max}}$  设置为 0.9,  $BW_{\text{min}}$  设置为 0.1。

#### 3.2 训练仿真

从上文得到的信道状态数据中选取连续的 11 100 组数据,其中第 1 组 ~ 第 1 000 组数据进行 BPNN 的训练,第 1 001 组 ~ 第 1 100 组数据进行 BPNN 的预测,第 1 101 组 ~ 11 100 组数据进行集合预测实验,每组数据包含有 4 个目标输入作为 BPNN 的输入值和 1 个目标输出作为 BPNN 的目标输出值。图 2 分别给出了基于 HS-BP、基于 DE-BP 和基于 BP 的神经网络频谱预测模型训练时均方误差随着训练次数变化的曲线对比。

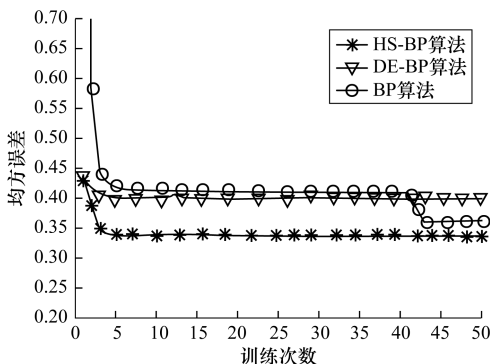


图 2 基于 HS-BP, DE-BP 和 BP 算法的神经网络频谱预测模型训练时均方误差对比

从图 2 可以看出,使用 HS 算法优化后的权重和

阈值进行 BPNN 的训练的误差要比直接随机生成权重和阈值以及使用 DE 优化后的权重和阈值进行 BPNN 的训练误差要明显小一些,这也说明了本文提出的 HS-BP 算法的可行性。

#### 3.3 预测仿真

训练完成之后,接着使用后面 100 组数据进行 BPNN 的预测。图 3 和图 4 分别为基于 HS-BP 与基于 BP 的神经网络频谱预测模型预测结果的误差以及基于 HS-BP 与基于 DE-BP 的神经网络频谱预测模型预测结果的误差对比曲线,将它们分开比较,是为了更加清晰地呈现它们之间的对比结果。

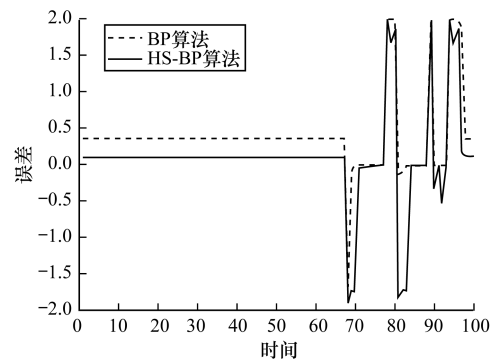


图 3 基于 HS-BP, BP 算法的神经网络频谱预测模型预测结果误差对比

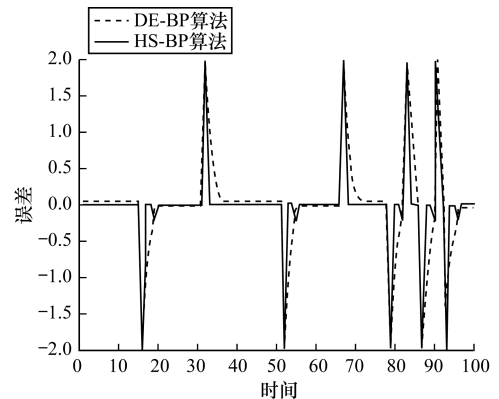


图 4 基于 HS-BP, DE-BP 算法的神经网络频谱预测模型预测结果误差对比

从图 3、图 4 可以看出,基于 HS-BP 的神经网络频谱预测模型的预测结果误差比基于 BP 神经网络预测模型的预测结果误差要小很多,比基于 DE-BP 的神经网络频谱预测模型的预测结果误差总体也要小一些,差距不是很明显,主要是由于基于 DE-BP 的神经网络频谱预测模型是在 BP 神经网络频谱预测模型的基础上进行优化过的,但从图 4 也可以看出,基于 HS-BP 的神经网络频谱预测模型的预测结果误差总体还是比基于 DE-BP 的神经网络频谱预测模型的预测结

果误差要小。这也说明了本文提出的基于 HS-BP 神经网络频谱预测方法的有效性。

在产生的信道状态数据中,继续取 10 000 组数据,并且把它们划分为 100 个数据集合,每个集合中包含 100 组数据,图 5、图 6 分别为每个数据集合中基于 HS-BP 与基于 BP 的神经网络频谱预测模型预测结果的均方误差的平均值对比,以及基于 HS-BP 与基于 DE-BP 的神经网络频谱预测模型预测结果的均方误差均值的平均值对比曲线。从图 5、图 6 中可以看出,对于每个数据集合的平均均方误差值,基于 HS-BP 的神经网络频谱预测模型的预测结果明显比基于 BP 神经网络预测模型的预测结果和基于 DE-BP 的神经网络频谱预测模型的预测结果要更好一些,这也充分证明了本文提出的基于 HS-BP 的神经网络频谱预测方法整体上要比其他 2 种方法的预测准确性更高。

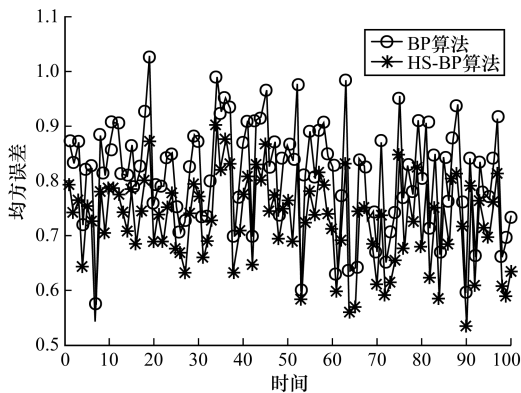


图 5 基于 HS-BP、BP 算法的神经网络频谱预测模型预测结果均方误差的平均值对比

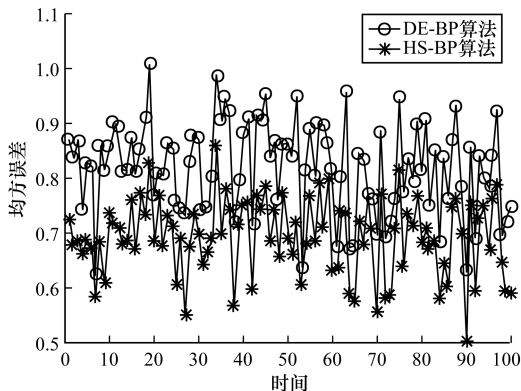


图 6 基于 HS-BP、DE-BP 算法的神经网络频谱预测模型预测结果均方误差均值的平均值对比

根据式(17),假设 PU 的平均到达间隔时间  $t_{\text{inter}}$  保持不变,图 7 给出了不同通信强度  $\rho$  下基于 BP 神经网络频谱预测、基于 DE-BP 神经网络频谱预测和基于 DE-BP 神经网络频谱预测的均方误差值对比。

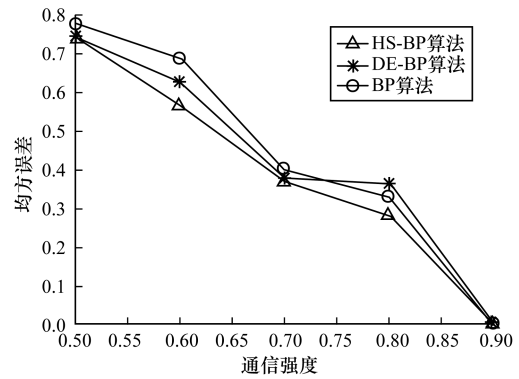


图 7 不同通信强度下 3 种算法频谱预测的均方误差对比

从图 7 可以看到,在不同通信强度下,本文提出的 HS-BP 算法的表现相对于其他 2 种算法要更好一些,尤其是在通信强度  $\rho$  为 0.6 时表现最突出。

#### 4 结束语

在认知无线网络中,频谱感知是 SU 决定是否使用 PU 信道的一个重要方法,但是频谱感知需要大量的能耗,使用频谱预测可以有效地解决频谱感知所存在的问题,因此,提高频谱预测的准确性是提高 PU 频谱使用效率的关键。基于此,本文提出一种基于 HS-BP 的神经网络频谱预测算法,在 CRN 的频谱预测中,通过使用 HS 算法来优化 BPNN 算法。实验结果表明,HS-BP 频谱预测算法可以有效提高预测的准确性。但是 HS-BP 神经网络预测算法可能会延长系统的预测时间而导致空闲信道无法被及时利用,进而影响到频谱的使用效率。因此,对于预测时间与频谱使用效率的协调关系需要进一步研究。

#### 参考文献

- [1] Mitola J, Maguire G Q. Cognitive Radio: Making Software Radios More Personal[J]. IEEE Personal Communications, 1999, 6(4): 13-18.
- [2] Haykin S. Cognitive Radio: Brain-empowered Wireless Communications[J]. IEEE Journal on Selected Areas in Communications, 2005, 23(2): 201-220.
- [3] Tumuluru V K, Wang P, Niyato D. A Neural Network Based Spectrum Prediction Scheme for Cognitive Radio[C]// Proceedings of IEEE Conference on Communications. Cape Town, South Africa: [s. n.], 2010: 1-5.
- [4] Tumuluru V K, Wang P, Niyato D. Channel Status Prediction for Cognitive Radio Network[J]. Wireless Communications and Mobile Computing, 2012, 12(10): 862-874.
- [5] 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.

(下转第 155 页)

通过图4的分析和对比,可以看出采用子载波配对技术再结合自适应转发算法,系统可以在一个很宽的信噪比区间获得更高的信道容量性能。

#### 4 结束语

本文研究在认知无线场景下,基于自适应转发算法的OFDM中继协作通信中的资源分配问题。在保证对主要用户引入的干扰小于门限值的前提下,系统能够获得最大的信道容量,通过使用自适应中继转发策略使整个系统能够在更宽的信噪比区间获得相对最优的信道容量性能。仿真结果证明了本文优化算法可以达到一个近似最优的性能,将该优化方案结合子载波配对技术可提高系统的信道容量,在实时通信业务中具有重要的意义。

#### 参考文献

- [1] Qin Tao, Leung C, Shen Z. Resource Allocation in a Cognitive Radio System with Imperfect Channel State Estimation[J]. Electrical and Computer Engineering, 2014, 26(3): 51-56.
- [2] Haykin S. Cognitive Radio: Brain-empowered Wireless Communications[J]. IEEE Journal on Selected Areas in Communications, 2005, 23(2): 201-220.
- [3] 卢云波,唐 亮,郝李欣,等.多用户认知无线电OFDM系统的资源分配算法[J]. 计算机工程, 2015, 41(7): 111-114, 119.
- [4] Li Liying, Zhou Xiangwei, Xu Hongbing, et al. Simplified Relay Selection and Power Allocation in Cooperative Cognitive Radio Systems[J]. IEEE Transactions on Wireless Communications, 2011, 10(1): 33-36.
- [5] 谢先斌,李新山.基于频谱感知的认知无线网络容量研究[J]. 电子测量与仪器学报, 2010, 34(1): 61-65.
- [6] 姬士龙,郭 辉,马长栋,等.基于最佳中继选择的认

知译码转发系统性能分析[J]. 计算机工程, 2015, 41(7): 153-156.

- [7] Li Yonghui, Vucetic B. On the Performance of a Simple Adaptive Relaying Protocol for Wireless Relay Networks[C]// Proceedings of IEEE Vehicular Technology Conference. Washington D.C., USA: IEEE Press, 2008: 2400-2405.
- [8] Khan A, Kuhn V. Power Optimization in Adaptive Relay Networks[C]// Proceedings of IEEE Global Telecommunication Conference. Washington D. C., USA: IEEE Press, 2010: 508-513.
- [9] Hsu C N, Su H J, Lin P H. Joint Subcarrier Pairing and Power Allocation for OFDM Transmission with Decode-and-forward Relaying[J]. IEEE Transactions on Signal Processing, 2011, 59(1): 399-414.
- [10] Pei Errong, Wang Sheng, Zhang Zhizhong. Capacity and Optimal Power Allocation for Spectrum-sharing with Primary Transmission Consideration in Fading Channels[J]. IEEE Communications Letters, 2011, 15(4): 389-391.
- [11] Musavian L, Aissa S S, Lambotaran S. Effective Capacity for Interference and Delay Constrained Cognitive Radio Relay Channels[J]. IEEE Transactions on Wireless Communications, 2010, 9(5): 1698-1707.
- [12] Dang Wenbing, Tao Meixia, Mu Hua, et al. Subcarrier-pair Based Resource Allocation for Cooperative Multi-relay OFDM Systems[J]. IEEE Transactions on Wireless Communications, 2010, 9(5): 1640-1649.
- [13] 王仕果,易 进,彭海霞.中继协作认知无线电系统的最优化功率分配[J]. 计算机工程, 2015, 41(5): 93-96, 101.
- [14] Tang Jia, Zhang Xi. Cross-layer Resource Allocation over Wireless Relay Networks for Quality of Service Provisioning[J]. IEEE Journal on Selected Areas in Communications, 2007, 25(4): 645-656.
- [15] Bertsekas D P. Nonlinear Programming[M]. Nashua, USA: Athena Scientific, 1999.

编辑 刘 冰

(上接第150页)

- [6] 张德慧,张德育,刘清云,等.基于粒子群算法的BP神经网络优化技术[J]. 计算机工程与设计, 2015, 36(5): 1321-1326.
- [7] 戴朝华. 粒子群优化算法综述[EB/OL]. (2016-05-26). <http://www.sciencetimes.com.cn/u/dchzyf/>.
- [8] Chen Ze, Hu Zhen, Qiu R C. Quickest Spectrum Detection Using Hidden Markov Model for Cognitive Radio[C]// Proceedings of IEEE Military Communications Conference. Boston, USA: [s. n.], 2009: 1-7.
- [9] Buscema M. Back Propagation Neural Networks[J]. Substance Use & Misuse, 1998, 33(2): 233-270.
- [10] Geem Z W, Kim J H, Loganathan G V. A New Heuristic Optimization Algorithm: Harmony Search[J]. Simulation, 2001, 76(2): 60-68.
- [11] Kattan A, Abdullah R. Training Feed-forward Artificial Neural Networks for Pattern-classification Using The Harmony Search Algorithm[J]. Digital Enterprise and Information Systems, 2013, 9(11): 84-97.

- [12] Lee K S, Geem Z W. A New Meta-heuristic Algorithm for Continuous Engineering Optimization: Harmony Search Theory and Practice[J]. Computer Methods in Applied Mechanics and Engineering, 2005, 194(36): 3902-3933.
- [13] Mahdavi M, Fesanghary M, Damangir E. An Improved Harmony Search Algorithm for Solving Optimization Problems[J]. Applied Mathematics and Computation, 2007, 188(2): 1567-1579.
- [14] 韩红燕,潘全科,梁 静.和声搜索算法在函数优化中的应用[J]. 计算机工程, 2010, 36(13): 245-247.
- [15] Abdrabou A, Zhuang W. Service Time Approximation in IEEE 802.11 Single-hop Ad Hoc Networks[J]. IEEE Transactions on Wireless Communications, 2008, 7(1): 305-313.
- [16] 吕 雪.基于MATLAB的网络排队仿真[D].大连:大连海事大学, 2013.

编辑 索书志