

# 基于人工智能技术的认知无线网络重构决策算法

贺倩<sup>1,2</sup>, 冯志勇<sup>1,2</sup>, 张平<sup>1,2</sup>

(1. 北京邮电大学 无线新技术研究所, 北京 100876; 2. 北京邮电大学 泛在网络教育部重点实验室, 北京 100876)

**摘要:** 认知无线网络引入重构技术以实现对复杂时变环境的动态适应, 为在认知无线网络中实现重构, 提出了重构架构模型, 并在此模型基础上进行重构决策算法的研究, 提出了基于人工智能技术的重构决策算法。该决策算法包括了推理过程和学习过程, 使重构技术在认知无线网络感知能力、推理能力和学习能力的帮助下实现了对环境的适应并同时维护和提升了系统性能。

**关键词:** 重构决策; 认知无线网络; 推理; 学习; 人工智能

中图分类号: TN915.02

文献标识码: A

文章编号: 1000-436X(2012)07-0096-07

## Reconfiguration decision making based on artificial intelligence technology in cognitive radio networks

HE Qian<sup>1,2</sup>, FENG Zhi-yong<sup>1,2</sup>, ZHANG Ping<sup>1,2</sup>

(1. Wireless Technology Innovation Institute, Beijing University of Posts and Telecommunications, Beijing 100876, China;

2. Key Laboratory of Universal Wireless, Communications Ministry of Education, Beijing University of Posts and Telecommunications, Beijing 100876, China)

**Abstract:** Cognitive wireless networks introduced the reconfiguration technologies to achieve the dynamically time-varying adaptation of the environment. A reconfiguration decision making model and reconfiguration decision algorithm based on the artificial intelligence technology were presented. The reconfiguration decision algorithm, which include the reasoning and learning process with the help of the cognitive capabilities of awareness, reasoning and learning, could achieve adaptation of the environment and also maintain and enhance the system performance.

**Key words:** reconfiguration decision; cognitive wireless network; reasoning; learning; artificial intelligence

### 1 引言

认知无线电概念最初的提出是因为其具有良好的感知能力、推理和学习能力。这些能力使得认知无线电技术可以动态地调整频谱使用情况从而进一步的提高频谱利用率<sup>[1]</sup>。这无疑缓解了目前频谱资源紧缺的局面。但是随着通信技术的进一步发展, 引入了认知概念的无线网络正向复杂化、异构化以及动态化的方向进行转变<sup>[2]</sup>。一些传统的网络

管理方式已经不适用于当前网络所面临的复杂情况。所以为了有效地管理网络以便应对这些挑战, 本文在认知无线网络中引入了重构技术。重构技术通过改变一系列无线参数以及调整相应的网络行为对认知无线网络进行性能维护。这种维护可以在环境和系统需求发生动态变化的时候既保证了网络性能又兼顾用户需求。应用于认知无线网络的重构技术能为网络提供一种更加灵活、更具有自适性的网络管理方法, 但是与此对应的是, 重构技术在

收稿日期: 2011-07-12; 修回日期: 2012-02-29

基金项目: 国家重点基础研究发展计划(“973”计划)基金资助项目(2009CB320400); 国家科技重大专项(2010ZX03003-001-01); 国家自然科学基金资助项目(61121001)

**Foundation Items:** The National Basic Research Program of China (973 Program) (2009CB320400); The National Science and Technology Major Project (2010ZX03003-001-01); The National Natural Science Foundation of China (61121001)

认知网络中的实现也需要依靠认知网络所特有的感知能力、预测能力以及学习能力。两者相辅相成，进一步实现了系统性能的提升。

重构决策的制定是重构技术实现的关键部分。重构决策首先通过分析影响性能的因素得出需要进行改变的网络参数，随后通过计算进行重构部署，把这些改变映射到实际的网络结构中去。这样既保证系统能适应动态变化的环境，同时也节省了系统操作的时间。目前对于重构决策的研究涵盖了很多方向，包括对于路由重构的研究<sup>[3,4]</sup>，对于协议重构的研究<sup>[5]</sup>以及对于参数重构的研究<sup>[6,7]</sup>。其中参数重构的重点主要是分析影响系统性能的各参数关系，得到参数与系统性能之间互相影响的准则，并依据这些准则更新单个或一组参数值以提升或者维持系统性能。在文献[6]和文献[7]中，Troy Weingart 等人使用 DOE (design of experiment) 技术对参数间关系进行分析。DOE 是指通过进行多次实验以试探某个参数的改变对系统性能产生的影响从而总结出参数与网络性能之间的关系。但是，可以预见的是由于在认知无线网络中涉及的参数数量众多且关系复杂，而这样多参数多目标的重构需要的计算比较复杂，因此 DOE 过程中涉及到的计算量也是比较大的，这样使得重构操作所花费的时间没办法保证。

在本文中，引入神经网络和专家系统这 2 种人工智能技术来解决上述的多目标优化问题。专家系统可以对多域参数进行分析并形成简单的规则以减少系统决策的计算时间。而神经网络可以同时接受多个输入，这更适合于处理认知无线网络中复杂的多域信息。同时，神经网络技术具有学习能力，可以通过对训练数据的分析以及对历史数据的学习而获得经验进而更好地完成重构决策。针对简单网络环境和复杂网络环境 2 种场景下的不同特点，提出了 2 种算法，这样能够在保证决策有效性的前提下尽量减少决策过程中的计算量：专家重构决策算法是指仅借助于专家系统的前向和后向搜索算法，这样可以迅速得到决策结果，适用于简单的网络环境；结合神经网络与专家系统的重构决策算法能够应对更加复杂的情况，适用于有多参数的复杂网络环境中。

本文的结构如下：第 2 节，阐述重构决策的架构基础，并描述在决策过程中的信息收集过程；第 3 节对 2 种不同的重构算法进行阐述；第 4 节对多参数认

知无线网络重构算法进行仿真并分析了仿真结果；第 5 节为结束语。

## 2 重构决策的架构基础

### 2.1 系统架构

为了体现认知无线网络中特有的感知过程、推理过程、学习过程、决策过程以及行动过程，本文提出的重构决策架构中包含了推理引擎、学习引擎、规则引擎、决策引擎以及行动引擎几个模块。图 1 展示了各个模块的相互联系。

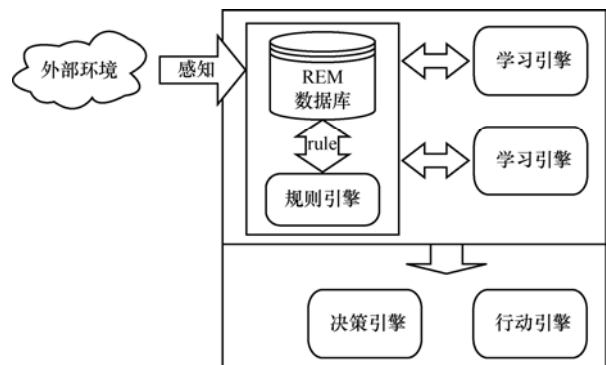


图 1 重构决策的架构基础

为制定重构决策首先要获知完整的外部环境信息以及无线控制参数信息。这些信息由感知技术收集，并以系统可以理解的形式储存于系统中的无线环境映射 (REM, radio environment map) 数据库中。REM 数据库对这些数据进行分类存储以便为重构决策提供数据基础，并在整个运行过程中进行动态化的更新。

规则引擎在综合考虑环境信息、无线参数信息以及相关政策规则信息的基础上推导出无线参数与系统性能之间的相互作用关系，并把这些关联信息输入到数据库中。基于这些关联信息建立起来的具有预测能力的推理模型就可以在动态变化环境中自适应地选择合适的配置以满足系统性能需求。

为了实现认知无线网络的主动性并节省重构时间，推理引擎会首先借助于规则引擎得出的一系列规则以及人工智能技术中的专家系统算法建立起一个先验分析模型。该模型在面对简单网络结构时可以直接推导出可能的认知网络重构方法。

学习引擎通过从历史信息以及环境信息中学习经验来优化推理引擎产生的结果，进而把优化结果存储进数据库中并为下一次的决策制定服务。学习引擎主要参与在复杂网络结构中的重构决策制定，以弥补

推理引擎在面对复杂数据处理时的一些不足。

决策引擎是把之前推理引擎和学习引擎的计算结果映射为重构决策并传递给行动引擎，行动引擎按照决策来调动系统进行参数改变以及无线行为调整。

### 2.2 推理和学习阶段的信息收集与规则推导

正如前文所述，将无线环境的复杂多域信息映射到数据库中是重构决策的第一步。这些多域数据描述了环境信息、系统需求以及节点能力。REM 数据库正是这样一种能存储复杂多域信息的数据库。如图 2 所示，REM 数据库可以存储诸如地理信息、可用服务、频谱规则、定位信息、用户或运营商规则信息和过去的经验信息等一系列的数据<sup>[8]</sup>。为了实现重构决策中基于规则的推理过程，这里 REM 数据库也存储从规则引擎中得出的规则。

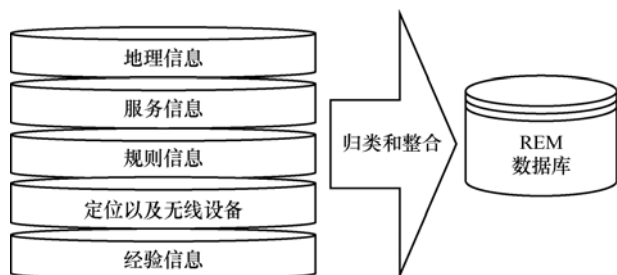


图 2 REM 数据库结构

在收集信息的过程中，REM 多域数据库分别以本地 REM 数据库和全局 REM 数据库 2 种形式进行认知信息的收集与管理。全局数据库一般位于网络侧，它所收集的信息更加全面和具体。而本地数据库位于终端侧，主要侧重收集终端的认知信息。由于重

构决策需要由网络侧和终端侧共同协商进行，因此在整个重构操作的进行过程中本地数据库要与全局数据库进行频繁的数据交互保证重构决策的有效性。

## 3 基于人工智能技术的重构决策算法

推理引擎和学习引擎是完成认知网络中重构决策的主要部分。推理引擎通过将现存知识映射到当前环境条件中进行系统行为和配置的管理。学习引擎则通过学习历史信息与经验对认知网络中的操作进行优化。此外，学习引擎与推理引擎相互影响，相互促进：学习过程丰富了推理过程中要使用到的知识，并优化推理引擎的输出结果；推理引擎提供了更多的训练数据和实例用于训练并初始化新的学习引擎。

就学习和推理之间的这种微妙关系来看，人工神经网络（实现学习过程）结合以规则为基础的专家系统（实现推理过程）可实现一个完整的推理学习过程，完成以系统需求为目标的重构决策。一个完整的基于人工神经网络和规则专家系统的决策模型如下图 3 所示。首先规则专家系统基于规则引擎中推导出的规则进行推理。同时，这些规则作为训练数据输入基于神经网络的学习引擎。这样当新的环境信息被输入到已经训练好的学习引擎时，学习引擎可以产生一系列新的规则。借助于这些新的规则，推理引擎可以对产生的重构决策进行优化。

### 3.1 基于规则的推理引擎

REM 数据库中存储的规则是以“IF THEN”形式来展现系统参数与系统性能之间影响关系的。在这里无线参数的集合定义为  $\{s_1, s_2, \dots, s_n\} \subset S$ 。S 代表整个无线参数集合， $s_i (i \in (1, n))$  是影响系统性能的

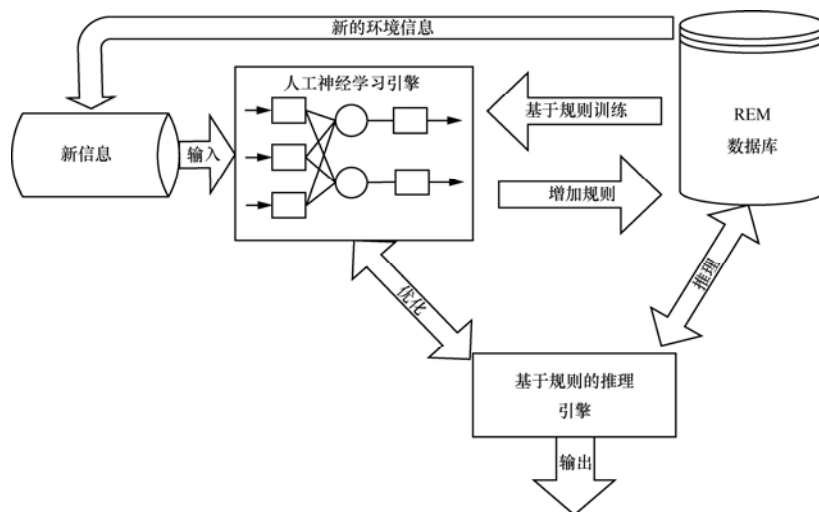


图 3 基于神经网络和规则专家系统的决策模型

单个无线参数，例如信道编码、传输功率、地理位置、调制模式、信道带宽、服务类型等。同样的，系统性能由  $\{H_1, H_2, \dots, H_m\}$  表示，其中， $H_j (j \in (1, m))$  是表征系统性能的参数，例如吞吐量、SNR、BER 等。所以存储在数据库中的规则可以描述为“IF  $s_i$  THEN  $H_j$ ”。

推理引擎在重构决策制定过程中的工作情况如图 4 所示。在网络情况平稳的状态下，重构计算操作处于闲置状态，只有在系统需求发生改变或环境信息发生改变时重构计算过程才被唤醒，开始进行重构决策。

当系统需求变化的时候，一系列无线参数应被重构以达到新的系统目标。在这种条件下，重构决策是由基于规则专家系统的后向链接算法完成的。

1) 初始化规则空间并映射系统需求到  $H_k$ 。

2) 在当前数据库的集合  $\{H_1, H_2, \dots, H_m\}$  中寻找可以匹配  $H_k$  的系统性能参数。

3) 如果搜索成功，后项包含  $H_k$  的规则将被激活。也就是能获得系统需求的规则被寻找到。否则，跳出搜索。

4) 分析被激活规则的前项，这样就得出需要进行调整的无线参数。这个结果就可被映射为重构决策。

当环境信息发生改变时，一些无线参数也随之变化。为避免这种变化影响系统性能，系统应有能力预测可能的危害以便提前采取措施。这种提前部

署的实现由前向算法与后向算法联合完成。

1) 初始化规则空间并映射新的无线参数到  $s_k$ 。

2) 在现存数据库中的集合  $\{s_1, s_2, \dots, s_n\}$  中寻找与  $s_k$  匹配的项。

3) 如果搜索成功，前项是  $s_k$  的规则会被激活。否则，跳出搜索。

4) 分析选定规则的后项部分，由此可以预测到由于无线参数变化而引起的系统性能改变。如果这种性能改变是向好的方面发展的，那么可以结束算法，否则将该性能参数映射为  $H_s$  并定义其相反数  $-H_s$ 。

5) 在集合  $\{H_1, H_2, \dots, H_m\}$  中寻找  $-H_s$  的匹配项。

6) 如果匹配成功，那么就会有相应的规则被激活。否则跳出搜索。

7) 分析该激活规则的前项就可得到需要改善的无线参数信息。这样的情况就可映射为重构决策，以便进一步进行重构操作。

整个算法应用到的搜索都是依据精确条件进行匹配的，也就是说一个模糊的搜索选项会导致搜索失败。这也是为什么单独的推理算法只应用于简单的网络结构。在面对复杂系统时，推理算法需要结合学习算法以达到较好的性能。

### 3.2 推理与学习相结合的重构决策算法

学习引擎的优势体现在 3 个方面。首先，学习引擎可以学习环境信息从而生成新的规则并实时更新数据库中的规则存储；其次，学习过程中可以

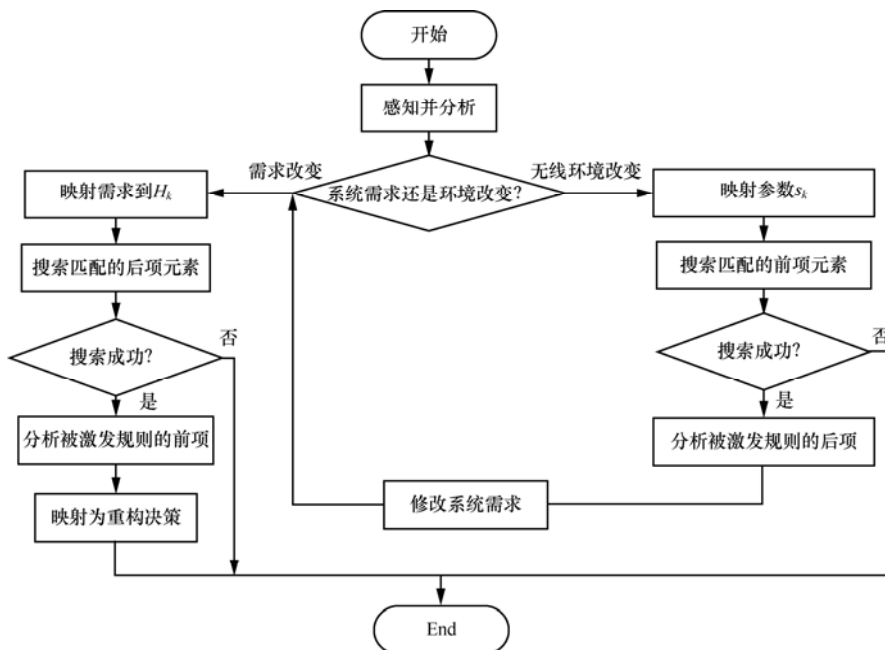


图 4 推理引擎在重构决策制定过程中的工作流程

应用模糊搜索进行近似推理，这样提高了推理的可靠性；最后，学习引擎可以提取目标函数并通过优化目标函数来优化推理结果。

本文提出一个结合人工智能和规则专家系统的学习算法来实现以上关于学习引擎的种种优势。该算法经过训练过程（学习过程）、推理过程以及优化过程得出重构决策。算法如下所述。

**第 1 步 初始化。**

1) 初始化规则空间并将规则映射到 3 层的人工神经网络模型上。规则的前项部分（无线参数部分）映射到第 1 层（输入层）。后项部分（描述系统性能部分）映射到第 3 层（输出层）。中间的隐藏层代表输入层与输出层之间的映射关系。

2) 分别定义  $\omega_{ik}$  和  $\omega_{kj}$  作为输入层（有  $i$  个神经元）和隐藏层（有  $k$  个神经元）的权值。依次对每个神经元初始化权值  $\omega_{ik}$  和  $\omega_{kj}$ 。权值应反映输入层的无线参数在相应规则中影响程度的大小，影响越大其对应权值就越大。

3) 初始化输入  $s_i(i \in (1, n))$  和输出  $H_j(j \in (1, m))$ 。初始化所需要的训练数据由 REM 数据库提供。

**第 2 步 设定激活函数。**

1) 计算隐藏层第  $k$  个神经元的实际输出：

$$y_k(p) = \text{sigmoid}[\sum_{i=1}^n x_i(p) \times \omega_{ik}(p)] \quad (1)$$

其中， $x_i(p)$  是第  $p$  次迭代过程中输入层第  $i$  个神经元的输入， $n$  是隐藏层第  $k$  个神经元全部输入的个数， $\text{sigmoid}()$  是 sigmoid 激活函数。

2) 计算输出层第  $j$  个神经元的实际输出如下：

$$y_j(p) = \text{sigmoid}[\sum_{k=1}^l x_{kj}(p) \times \omega_{kj}(p)] \quad (2)$$

其中， $x_{kj}(p)$  是在第  $p$  次迭代过程中隐藏层第  $k$  个神经元对输出层第  $j$  个神经元的输入， $l$  是输出层第  $j$  个神经元总的输入个数。

**第 3 步 用反向传播算法进行训练。**

反向传播（BP, back propagation）算法主要是将输出与输入进行比较计算出误差，并通过调节权值使误差趋近于零<sup>[9]</sup>。本文用误差斜率来表示误差大小。

1) 输出层误差斜率计算如下：

$$\delta_j(p) = y_j(p) \times [1 - y_j(p)] \times (y_{d,j}(p) - y_j(p)) \quad (3)$$

其中， $y_{d,j}(p)$  是训练数据中输入所对应的期望输出。随后矫正权值应以如下方式计算：

$$\Delta\omega_{kj}(p) = y_k(p) \times \delta_j(p) \quad (4)$$

那么输出层的权值就更新为

$$\omega_{kj}(p+1) = \omega_{kj}(p) + \Delta\omega_{kj}(p) \quad (5)$$

2) 隐藏层的误差斜率计算如下：

$$\delta_k(p) = y_k(p) \times [1 - y_k(p)] \times \sum_{j=1}^m \delta_j(p) \times \omega_{kj}(p) \quad (6)$$

矫正权值应以如下方式计算：

$$\Delta\omega_{ik}(p) = x_i(p) \times \delta_k(p) \quad (7)$$

隐藏层的权值更新如下：

$$\omega_{ik}(p+1) = \omega_{ik}(p) + \Delta\omega_{ik}(p) \quad (8)$$

**第 4 步 迭代。**

令  $p=p+1$  然后返回第 2 步直到误差斜率趋近于零。

**第 5 步 应用经过训练的神经网络模型进行推理与决策制定。**

1) 新规则的产生

经过迭代之后，已经训练完成的神经网络系统就可以反映认知网络当前的状态了，并且可以实现学习引擎的种种优势。

当新的信息输入到训练完成的人工神经网络系统时，将得到相应的输出，如果这个输出是与之前的一些结果不相一致的新结果，那么可以将该输入和输出映射为一条新的规则放入 REM 数据库中。否则不修改数据库中的规则信息。

2) 通过已训练模型进行模糊推理

当信息不足以通过规则进行推理时，训练完成的神经网络模型将提取权值并进行分析。用已知参数所对应的权值之和与未知参数所对应的权值之和进行对比，如果已知参数权值之和大于未知参数权值之和，那么仍然可以推导出该规则所指向的结果，否则该规则必须等待更多相关信息的输入才能做出判断。

3) 将推理与学习得出的结果映射为重构决策

神经网络能够不断对外界环境进行学习，这样训练过的模型才能体现系统的一个实时状态。神经网络与规则专家系统相结合的算法将推理和学习良好地结合起来进行决策制定，这样保证了重构决策的合理性与可靠性。

**4 算法性能仿真**

在仿真过程中，数据传输速率（ $dr$ ）、发射功率（ $tp$ ）、帧长（ $fs$ ）和噪声程度（ $n$ ）这 4 个参数代表无线参数，系统的吞吐量（ $T$ ）作为系统性能的度量参数。仿真在 3 种情况下分别展示无线参数对于系统性能的影响程度：使用神经网络结合规则专家系统的算法进行重构决策时，使用最差配置时，

使用最佳配置时。最佳配置以及最差配置如表 1 所示：是指能够产生最佳或者最差的系统性能的参数。神经网络结合规则专家系统的算法仿真是从最保守的配置条件下（相当于最差的配置）开始的。随后它自适应地调节参数以满足系统性能的需求。

**表 1 最差配置与最佳配置表**

| 配置方式 | 传输速率     | 发射功率 | 帧长     | 噪声水平    |
|------|----------|------|--------|---------|
| 最佳配置 | 11Mbit/s | 32W  | 20byte | 5dBm    |
| 最差配置 | 1Mbit/s  | 8W   | 8byte  | 10.3dBm |

本文采用一个 3 层的神经网络模型，含有一个输入层，一个中间隐藏层以及一个输出层。隐藏层神经元个数为 20，输出层神经元个数为 3，隐藏层以及输出层均采用 Sigmoid 传输函数。同时设定允许最大训练步数为 1 000，目标误差为 0.001，学习速率设为 0.1。同时用专家系统生成的规则（如图 5 所示）初始化这个 3 层的神经网络模型。

- 1) (dr==low)&(tp=="low)&(n=="low)=>(T=low)(1)
- 2) (dr==low)&(tp==low)&(n=="low)=>(T=low)(1)
- 3) (dr==low)&(tp==low)&(n==low)=>(T=low)(1)
- 4) (dr==medium)&(tp==medium)&(n==medium)=>(T=medium)(1)
- 5) (dr==medium)&(tp==high)&(n==low)=>(T=high)(1)
- 6) (dr==high)&(tp==medium)&(n==medium)=>(T=high)(1)
- 7) (dr==high)=>(T=high)(1)
- 8) (tp==high)=>(T=high)(1)
- 9) (n==high)=>(T=low)(1)
- 10) (n==low)=>(T=high)(1)
- 11) (tp==low)=>(T=low)(1)
- 12) (dr==low)=>(T=low)(1)
- 13) (dr==medium)&(tp==low)&(n==high)=>(T=low)(1)
- 14) (dr==medium)&(tp==medium)&(n==high)=>(T=low)(1)
- 15) (dr==medium)&(tp==high)&(n==high)=>(T=medium)(1)
- 16) (dr==high)&(tp==low)&(n==high)=>(T=medium)(1)
- 17) (dr==high)&(tp==high)&(n==high)=>(T=high)(1)
- 18) (dr==high)&(tp==medium)&(n==low)=>(T=high)(1)

图 5 规则信息

本文采用 24 组测试值进行神经网络模型的训练。图 6 给出了系统在训练过程中误差（神经网络输出值与训练数据之间的差值）变化的情况。误差在第 338 次迭代时趋向于 0.001。也就是说，此时神经网络模型已经训练完成，完成了对初始规则的更新与改正，可以表现出当前环境下各个无线参数和系统性能之间的关系。重构算法将基于这个训练完成的神经网络模型进行重构参数关系的分析，并进一步做出相应的重构决策。

将需要进行重构决策的参数（数据传输速率、发射功率、帧长和噪声）输入已经训练完成的神经网络系统中，并基于系统性能的变化情况用重构决策算法进行调整。设置情景如下：本次仿真持续时间是 180s；






图 6 训练过程中的误差变化

其中传输速率在 20s 到 90s 期间维持在 10Mbit/s，90s 到 130s 是 13Mbit/s，130s 到 180s 是 3Mbit/s；噪声在 40s 到 70s 为 0.81dBm，在 70s 到 110s 为 10.3dBm，110s 到 150s 为 8dBm，150s 到 180s 时为 3.2dBm。在此过程中，随着环境的不断变化，基于人工智能的重构算法会通过前面得出的参数-性能关系以最大化吞吐量为目标进行调节。图 7 给出了在整个仿真期间



(a) 功率变化情况



(b) 传输速率变化情况

图 7 采用重构算法与采用固定配置时的参数变化情况

传输速率和功率的变化情况。从中可以看出重构算法一直主动的对传输速率和功率进行调节,而采用静态配置只能随着环境改变,缺乏主动性。当噪声环境恶化的时候重构算法会调节发射功率或提高传输速率来保证系统性能。

图 8 给出了采用最好配置、最差配置和采用神经网络重构算法 3 种情况下的系统性能变化的比较。其中可以看出,采用了重构算法后,因为能自主应对环境变化所以吞吐量情况在大部分时间内要优于采用最优配置情况。同时,从节约能源的角度考虑,设置了系统吞吐量的最大值,使得重构不会进行无止境的优化,而会维持在一个能保证系统良好运行的平衡状态。




图 8 采用重构算法与采用固定配置的系统吞吐量比较

### 5 结束语

本文介绍了重构决策的制定过程,包括了重构决策架构以及重构决策算法。重构决策要涉及到一系列的过程,包括环境信息的感知与存储、参数间关系的建立与规则的推导、基于规则的推理过程以及基于神经网络的学习优化过程。这里提出了一种利用人工智能技术来制定重构决策的方法,一方面是因为人工神经网络擅长处理复杂的多域信息,另一方面是人工智能将学习机制引入重构决策制定,保证了重构决策的正确性与优化性。这样的重构决策算法可以灵活应对更多的无线参数,在保证认知无线网络性能的同时满足系统和用户的需求。

### 参考文献:

[1] MITOLA J. Cognitive radio for flexible mobile multimedia communications[J]. Mobile Network and Applications, 2001, 6(5):435-441.  
 [2] NICOLA B, MICHELE Z. Cognitive network access using fuzzy

decision making[J]. IEEE Transactions on Wireless Communications, 2009, 8(7): 3523-3535.  
 [3] SHIH C, LIAO W, CHAO H. Joint routing and spectrum allocation for multi-hop cognitive radio networks with route robustness consideration[J]. IEEE Transactions on Wireless Communications, 2011, 10(9): 2940-2949.  
 [4] GUAN Q, RICHARD Y, JIANG S. Prediction-based topology control and routing in cognitive radio mobile ad hoc networks[J]. IEEE Transactions on Vehicular Technology, 2010, 59(9):4443-4452.  
 [5] ANDREAS M, ELENI P, NANCY A. To reconfigure or not to reconfigure: cognitive mechanisms for mobile devices decision making[A]. Proceedings of the 2008 IEEE Vehicular Technology Conference(VTC)[C]. Calgary, AB, Canada, 2008.  
 [6] TROY W, DOUGLAS C S, DIRK G. A statistical method for reconfiguration of cognitive radios[J]. IEEE Wireless Communications, 2007, 14(4): 34-40.  
 [7] TROY W, GARY V Y, DOUGLAS C S. Implementation of a reconfiguration algorithm for cognitive radio[A]. Proceedings of the 2007 Cognitive Radio Oriented Wireless Networks and Communications (CrownCom)[C]. Orlando, FL, USA, 2007.  
 [8] ZHAO Y, MORALES L, GAEDDERT J, et al. Applying radio environment maps to cognitive wireless regional area networks[A]. IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks[C]. Dublin, Ireland, 2007.  
 [9] MICHAEL N. Artificial Intelligence: A Guide to Intelligent Systems, Second Edition[M]. England: Pearson Education, 2005.

### 作者简介:



贺倩 (1984-), 女, 吉林长春人, 北京邮电大学博士生, 主要研究方向为认知无线网络自管理与自优化、动态无线资源管理以及异构网络融合等。



冯志勇 (1971-), 女, 黑龙江哈尔滨人, 博士, 北京邮电大学教授, 主要研究方向为异构无线网络体系架构、3G/4G 网络中的无线资源管理、认知无线电技术、认知无线网络以及跨层设计等。



张平 (1959-), 男, 陕西汉中, 博士, 北京邮电大学教授, 主要研究方向为 3G 以及 B3G 系统中的关键技术、认知无线电技术、认知无线网络以及 MIMO-OFDM 等。