

# 一种用 ANN 实现带权不确定性推理的方法

施明辉, 周昌乐

(厦门大学 人工智能研究所, 福建 厦门 361005 E-mail smh@xmu.edu.cn)

**摘要:** 介绍了基于可信度的带权不确定性推理. 阐述了用神经网络(ANN)如何实现基于可信度的带权不确定性推理. 分析了这种神经网络的知识表示、结构及其不确定性推理方法. 说明了如何利用这种神经网络并行地实现多规则的基于可信度的带权不确定性推理, 以及如何解决冲突消解问题. 采用这种神经网络结构的系统不仅能实现基于可信度的带权不确定性推理, 而且具有自学习、并行推理、冲突消解、抗缺省等能力. 采用的神经网络结构突破了传统神经网络结构的设计思想, 对于扩展神经网络的应用具有参考价值.

**关键词:** 神经网络; 机器学习; 不确定性推理; 专家系统; 知识表示

**中图分类号:** TP18      **文献标识码:** A      **文章编号:** 0367-6234(2007)09-1491-05

## An approach to weighted uncertain reasoning based on artificial neural network

SHIMinghui, ZHOU Changle

(Institute of Artificial Intelligence, Xiamen University, Xiamen 361005, China, E-mail smh@xmu.edu.cn)

**Abstract** An approach to weighted reasoning under uncertainty with certainty factor (WRUCF) based on artificial neural network (ANN) was proposed. The related notions and inference method about WRUCF were presented. Then the new ANN to implement the inference of WRUCF was proposed and the details about the ANN were interpreted such as its structure and knowledge representation, its schema of uncertain reasoning as well as its mechanisms for parallel reasoning and conflict eliminating. A system exploiting this approach can not only implement WRUCF but also has the capabilities of self learning, parallel reasoning and conflict eliminating.

**Key words** artificial neural network; machine learning; uncertain reasoning; expert system; knowledge representation

不确定性知识的表示和处理作为人工智能的分支很早就受到重视和研究<sup>[1]</sup>, 产生了众多的理论和应用. 根据不确定性测度计算方法的不同, 不确定推理可以有基于概率理论的不确定推理, 基于模糊理论的不确定推理和基于可信度理论的不确定推理等. 基于概率理论的不确定推理具有概率论严密的理论依据, 模拟现实问题需要大量的条件概率, 而领域专家很少用数值形式表达概率, 使它的应用受到限制<sup>[2]</sup>. 基于模糊理论的不确定推理建立

在 1977 年由扎德 (Zadeh) 提出的模糊逻辑和可能性理论上<sup>[3]</sup>, 经过众多研究者的努力得到了广泛的应用. 基于可信度理论的不确定推理是肖特里菲 (E. H. Shortliffe) 等人在不确定性理论上提出的不确定推理方法, 并首先在著名的医疗诊断专家系统 MYCIN 中得到成功应用<sup>[4]</sup>.

人工神经网络 (ANN) 则是在对人脑组织结构 and 运行机智的认识理解基础之上, 模拟其结构和智能行为. 它具有自学习、大规模并行计算、非线性处理、鲁棒性、自组织及自适应性、存储与计算相结合等特点. 将人工神经网络应用于不确定推理系统, 可以将不确定性的推理过程变为神经网络的内部计算过程, 从而提高系统的智能水平.

本文首先介绍一种得到有效应用的基于可信

收稿日期: 2004-10-08.

基金项目: 国家自然科学基金资助项目 (60672018);

国家高技术研究发展计划资助项目 (2006AA01Z129);

厦门大学科技创新基金资助项目 (XDKJCY20063011).

作者简介: 施明辉 (1973-), 男, 博士研究生, 讲师;

周昌乐 (1959-), 男, 教授, 博士生导师.

度的带权不确定性推理, 然后提出一种能实现这种不确定性推理的新型人工神经网络. 这种人工神经网络不仅能实现基于可信度的带权不确定性推理, 而且具有自学习、并行推理、规则消解、抗缺省等能力.

### 1 基于可信度的带权不确定性推理

基于可信度的带权不确定性推理是在基于可信度的不确定性推理基础上实施的改进. 它在普通的不确定规则基础上增加了规则被使用的条件(阈限), 并为规则的各个证据赋以权值以表示它们各自对结论的重要性. 另外, 它还规定了不确定测度的推导方法. 采用基于可信度的带权不确定性推理更接近人脑的信息处理模式, 在专家系统、模式识别等领域有重要且有效的应用.

#### 1.1 相关概念<sup>[1]</sup>

##### 1.1.1 规则的可信度

人们对一个事物(或一事情)的认识, 往往可根据经验来判断这个事物(或一事情)在多大程度上可以被相信, 这种程度的度量概念就是可信度(Certainty Factor). 例如: 如果断定“明天百分之八十的可能会下雨”, 那么“明天下雨”的可信度为 0.8

若一条规则表示为: if  $e$  then  $h$ (其中  $e$  称为证据,  $h$  称为结论), 那么这条规则的可信度记为  $CF(h, e)$ . 相应地, 证据  $e$  和结论  $h$  的可信度分别记为  $CF(e)$  和  $CF(h)$ .

引入可信度后的规则可表示为:

$$\text{Rule. 1: if } e \text{ then } h (CF(h, e)).$$

其中  $e$  为证据,  $h$  为结论,  $CF(h, e)$  为规则的可信度.

理论上,  $CF(h, e)$  可以用概率的方法计算. 但是在实际应用中,  $CF(h, e)$  一般通过领域专家直接给出. 设定  $CF(h, e)$  值的原则是: 一般  $CF(h, e) \in [-1, 1]$ , 若相应的证据  $e$  能增加结论  $h$  为真的可信度, 则  $CF(h, e) > 0$  证据  $e$  支持结论  $h$  为真的程度越高,  $CF(h, e)$  的值越大; 反之, 若相应的证据  $e$  能增加结论  $h$  为假的可信度, 则  $CF(h, e) < 0$  证据  $e$  支持结论  $h$  为假的程度越高,  $CF(h, e)$  的值越小; 若证据  $e$  与结论  $h$  无关, 则  $CF(h, e) = 0$  这种方法简单直观、效果也较好.

##### 1.1.2 规则的阈限

规则的阈限是指与普通规则相关联的一个实数值  $\lambda$  给规则指定阈限后, 只有当规则相应的证据  $e$  的可信度满足条件  $CF(e) \geq \lambda$  时, 该规则才能被使用.

引入阈限后的规则表示为: if  $e$  then  $h (CF(h,$

$e), \lambda)$

##### 1.1.3 证据的权值

实际上, 证据  $e$  可以是一个简单证据, 也可以是多个证据的合取. 当  $e$  是多个证据的合取时, 记为  $e_1 \wedge e_2 \wedge \dots \wedge e_n$ . 一条规则中的多个证据对结论可以具有不同的支持程度. 为此, 在规则中可以对每个证据  $e_i (1 \leq i \leq n)$  引入一个反映其对结论支持程度的实数值  $w_i$ ,  $w_i$  称为  $e_i$  的带权因子. 通常规定  $0 \leq w_i \leq 1, i = 1, 2, \dots, n$  且应满足归

一条件: 
$$\sum_{i=1}^n w_i = 1$$

引入权值后的规则表示为:

$$\text{Rule. 2: if } e_1(w_1) \wedge e_2(w_2) \wedge \dots \wedge e_n(w_n) \text{ then } h (CF(h, e), \lambda)$$

其中  $e_i (1 \leq i \leq n)$  为证据,  $w_i$  表示  $e_i$  的带权因子,  $h$  为证据,  $CF(h, e)$  表示这条规则的可信度.

Rule. 2 是基于可信度的带权不确定性推理规则的一般表示方法.

#### 1.2 基于可信度的带权不确定性推理<sup>[1]</sup>

基于可信度的带权不确定性推理的一般过程是由给定的证据及各证据的可信度, 推断出规则(形如 Rule. 2)是否可用, 如果规则可用, 则进一步计算出根据此规则所得出的结论的可信度.

实际应用时, 以形如 Rule. 2 的规则所表示的知识存储在知识库中, 每条规则的  $CF(h, e), \lambda, w_i (1 \leq i \leq n)$  的值也由领域专家给出. 因此, 基于可信度的带权不确定性推理的实质是: 推理前, 各证据的可信度  $CF(e_i) (1 \leq i \leq n)$  作为已知条件, 已知的证据与知识库中规则的证据进行匹配, 若匹配成功, 则根据匹配成功的规则及其相应的  $CF(h, e), \lambda, w_i (1 \leq i \leq n)$  和  $CF(e_i) (1 \leq i \leq n)$ , 推断出此规则是否可用, 如果规则可用, 则进一步计算出根据此规则所得出的结论的可信度  $CF(h)$ .

整个推理过程可分为 3 个步骤:

1) 计算证据组合的可信度  $CF(e)$

对于形如 Rule. 2 的规则, 证据组合  $e$  由下式表达:

$$e = \bigwedge_{i=1}^n e_i(w_i),$$

其中: 一般  $w_i (1 \leq i \leq n)$  满足归一条件.

$n$  个证据组合的可信度可用下式计算:

$$CF(e) = \prod_{i=1}^n w_i \times CF(e_i).$$

2) 判断规则是否可用

对于形如 Rule. 2 的规则, 若  $CF(e) \geq \lambda$  时, 规则可用; 否则, 规则的使用无效.

3) 计算结论的可信度  $CF(h)$

对于形如 Rule 2 的规则, 结论的可信度  $CF(h)$  由下式给出:

$$CF(h) = CF(e) \times CF(h, e).$$

## 2 用神经网络实现基于可信度的带权不确定性推理

神经网络学习算法已有大量的研究成果<sup>[5]</sup>, 本文的神经网络学习算法可以采用 BP 算法<sup>[6]</sup>或其改进型算法.

### 2.1 结构与知识表示

#### 2.1.1 神经元符号

神经元模型已有很多种, 同种神经元模型在不同的文献中有不同的表示方法, 本文采用图 1 表示单个神经元模型<sup>[7]</sup>.




图 1 神经元模型一

其中  $p_i (1 \leq i \leq n)$  为神经元的输入;  $w_i$  为与输入  $p_i$  相应的神经元的连接权值;  $b$  为神经元的阈值, 与  $b$  相应的输入恒为  $-1$ ;  $f$  为神经元的传输函数;  $a$  为神经元的净输入,  $a = \sum_{i=1}^n p_i \times w_i - b$ ;  $c$  为神经元的输出,  $c = f(a) = f(\sum_{i=1}^n p_i \times w_i - b)$ .

当  $b = 0$  时, 简记为图 2




图 2 神经元模型二

#### 2.1.2 基于可信度的带权不确定性推理的神经网络表示

对于形如 Rule 2 的规则, 其不确定性推理采用如图 3 所示的两层神经网络表示.

##### 1) 输入层

输入层各输入分量表示规则的各证据的可信度, 即

$$P = [p_1 \ p_2 \ \dots \ p_n]^T = [CF(e_1) \ CF(e_2) \ \dots \ CF(e_n)]^T.$$

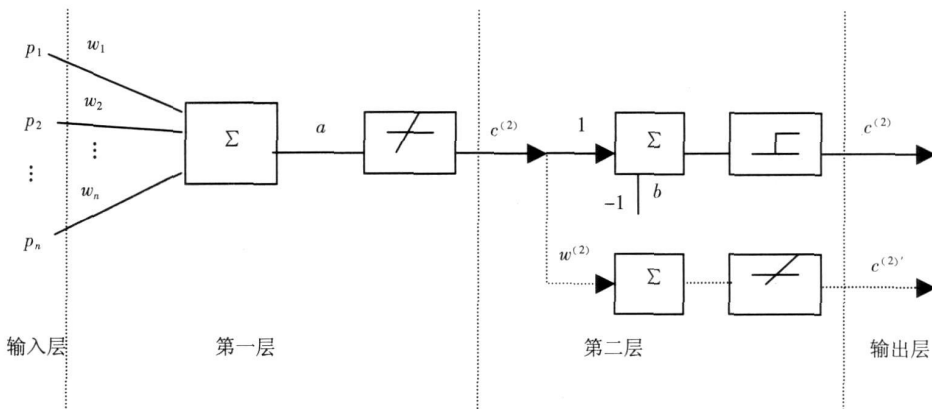


图 3 基于可信度的带权不确定性推理的神经网络表示

##### 2) 第一层

第一层中神经元不需要阈值, 即  $b = 0$ . 第一层中神经元的连接权值  $w_i (1 \leq i \leq n)$  表示相应的证据  $e_i (1 \leq i \leq n)$  的权值, 一般  $w_i$  应满足归一条件:  $\sum_{i=1}^n w_i = 1$ ; 第一层中神经元的净输入为  $a$ ,  $a$

满足公式  $a = \sum_{i=1}^n p_i \times w_i$ ; 第一层中神经元的传输函数是线性函数  $\text{purelin}$ , 第一层中神经元的输出为  $c^{(1)}$ ,  $c^{(1)}$  满足公式  $c^{(1)} = \text{purelin}(a)$ .

##### 3) 第二层

第二层中神经元分为两类, 分别用实线和虚线表示. 实线表示的神经元用来判断其规则是否可用, 称为“判断规则是否可用层”; 虚线表示的神经元用来计算结论的可信度, 称为“计算结论可信度层”.

“判断规则是否可用层”中神经元的输入为第一层的输出  $c^{(1)}$ ; 该层神经元的连接权值恒为  $1$ ; 神经元的阈值  $b$  表示规则的阈值  $\lambda$ , 即  $b = \lambda$ , 与其相应的输入恒为  $-1$ ; 该层神经元的传输函数是硬极限函数  $\text{hardlim}$ ; 该层神经元的输出为  $c^{(2)}$ ,  $c^{(2)}$  满足公式  $c^{(2)} = \text{hardlim}(c^{(1)} - b)$ .

“计算结论可信度层”中神经元的输入也为第一层的输出  $c^{(1)}$ ；该层神经元的连接权值  $w^{(2)}$  表示该规则的可信度，即  $w^{(2)} = CF(h, e)$ ；神经元的阈限  $b$  为 0 神经元的传输函数是线性函数  $\text{pure lin}$ ，神经元的输出为  $c^{(2)'}$ ， $c^{(2)'}$  满足公式  $c^{(2)'} = \text{pure lin}(c^{(1)} \times w^{(2)})$ 。

#### 4) 输出层

输出层即为第二层神经元的输出。值得注意的是，与一般的神经网络仅有一个输出不同，该神经网络的输出由  $c^{(2)}$  和  $c^{(2)'}$  共同构成。 $c^{(2)}$  反映规则使用的有效性， $c^{(2)'}$  反映使用该规则推出的结论的可信度。

### 2.2 不确定推理机制

#### 2.2.1 计算证据组合的可信度 $CF(e)$

计算证据组合的可信度  $CF(e)$  通过第一层神经元完成。如前所述，第一层的输出为  $c^{(1)}$ ， $c^{(1)}$  满足公式  $c^{(1)} = \text{pure lin}(a) = a$  其中， $a = \sum_{i=1}^n p_i \times w_i$ ，输入分量  $p_i$  即为规则的各证据的可信度  $CF(e_i)$ ；神经元的连接权值  $w_i (1 \leq i \leq n)$  等于相应的证据  $e_i (1 \leq i \leq n)$  的权值。因此， $c^{(1)} = \text{pure lin}(a) = a = \sum_{i=1}^n p_i \times w_i = \sum_{i=1}^n CF(e_i) \times w_i = CF(e)$ 。可见，第一层的输出表示了证据组合的可信度  $CF(e)$ 。

#### 2.2.2 判断规则是否可用

判断规则是否可用通过第二层中实线部分神经元完成，即由“判断规则是否可用层”完成。如前所述，“判断规则是否可用层”的输出为  $c^{(2)}$ ， $c^{(2)}$  满

足公式  $c^{(2)} = \text{hard lin}(c^{(1)} - b)$ 。其中， $c^{(1)}$  是第一层的输出，表示了证据组合的可信度  $CF(e)$ ；神经元的阈限  $b$  等于规则的阈限  $\lambda$ ，即  $b = \lambda$  因此，当  $c^{(2)} = 1$  时，必须  $c^{(1)} \geq b$  即  $CF(e) \geq \lambda$ ，故  $c^{(2)} = 1$  表示规则可以使用；当  $c^{(2)} = 0$  时，必须  $c^{(1)} < b$  即  $CF(e) < \lambda$ ，故  $c^{(2)} = 0$  表示规则不可以使用。

#### 2.2.3 计算结论的可信度 $CF(h)$

计算结论的可信度  $CF(h)$  通过第二层中虚线部分神经元完成，即由“计算结论可信度层”完成。如前所述，“计算结论可信度层”的输出为  $c^{(2)'}$ ， $c^{(2)'}$  满足公式  $c^{(2)'} = \text{pure lin}(c^{(1)} \times w^{(2)})$ 。其中， $c^{(1)}$  是第一层的输出，表示了证据组合的可信度  $CF(e)$ ；神经元的连接权值  $w^{(2)}$  表示了规则的可信度，即  $w^{(2)} = CF(h, e)$ 。因此  $c^{(2)'} = \text{pure lin}(c^{(1)} \times w^{(2)}) = c^{(1)} \times w^{(2)} = CF(e) \times CF(h, e) = CF(h)$ 。可见，“计算结论可信度层”的输出表示了结论的可信度  $CF(h)$ 。

值得注意的是，只有当“判断规则是否可用层”的输出  $c^{(2)}$  为 1 即规则可以使用时，“计算结论可信度层”的输出值  $c^{(2)'}$  才有效，此时  $c^{(2)'}$  表示的结论的可信度  $CF(h)$  才是不确定性测度的有效推理值；当“判断规则是否可用层”的输出值  $c^{(2)}$  为 0 即规则不可以使用时，“计算结论可信度层”的输出  $c^{(2)'}$  无效，此时  $c^{(2)'}$  表示的结论的可信度  $CF(h)$  不应当视为不确定性测度的有效推理值，但可以为其他的应用提供参考。

### 2.3 并行推理及冲突消解

图 3 可以表示一条规则的不确定性推理。这种方法可以扩展为表示多条规则，如图 4 所示。

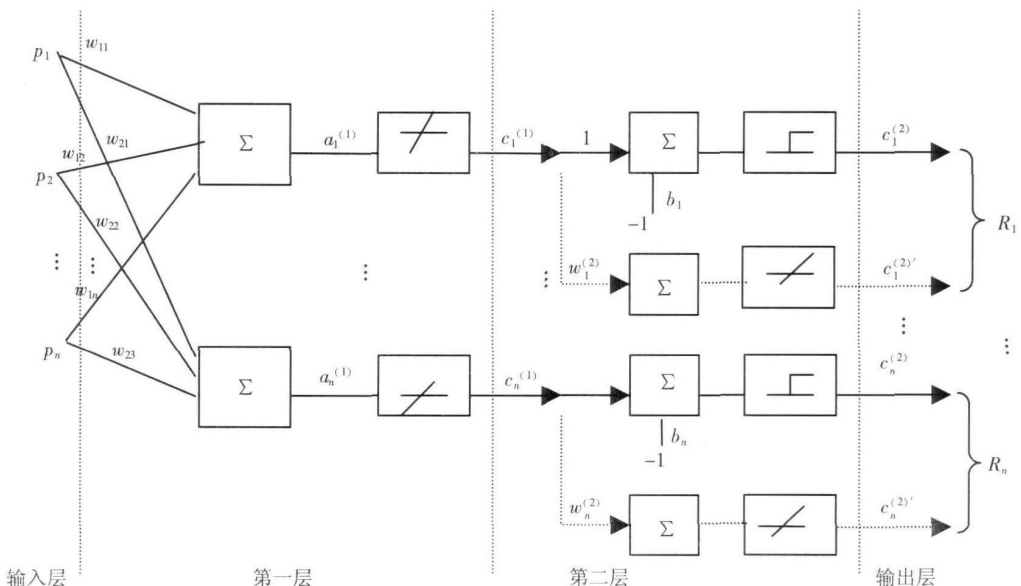


图 4 多规则并行推理的神经网络表示

1) 输入层

所有神经元的输入来自集合  $\{p_1, p_2, \dots, p_n\}$ , 各输入分量仍为规则的各证据的可信度值, 即

$$P = [p_1 \ p_2 \ \dots \ p_n]^T = [CF(e_1) \ CF(e_2) \ \dots \ CF(e_n)]^T$$

2) 第一层

第一层中每个神经元处理一条规则,  $w_k$  表示第  $i$  个神经元与第  $k$  个输入分量  $p_k$  的连接权值, 即表示第  $k$  个证据在神经元  $i$  所表示的规则中对结论的重要性大小. 第一层神经元  $i$  的净输入为

$$a_i^{(1)}, a_i^{(1)} \text{ 满足公式 } a_i^{(1)} = \sum_{k=1}^n w_{ik} \times p_k, \text{ 第一层神经元 } i \text{ 的输出为 } c_i^{(1)}, c_i^{(1)} \text{ 满足公式 } c_i^{(1)} = \text{purelin}(a_i)$$

3) 第二层

第二层中, 每条规则由两个神经元处理. 在图 4 中, 这两个神经元分别用实线和虚线表示, 其含义与图 3 完全相同. 将图 4 与图 3 相比较, 可以看出, 该层中相应的符号增加了下标, 用来表示神经元编号, 如  $c_n^{(1)}$  表示在第二层中第  $n$  个神经元的输入 (实际上也是第一层中第  $n$  个神经元的输出),  $c_n^{(2)}$  表示在第二层中第  $n$  个神经元的输出.

4) 输出层

输出层的含义与图 3 完全相同. 将图 4 与图 3 相比较, 可以看出, 该层中相应的符号也增加了下标用来表示神经元编号 (也是规则编号). 另外, 图中  $R_1$  表示第 1 条规则,  $R_n$  表示第  $n$  条规则.

图 4 中各条规则的不确定性推理可并行进行, 其推理机制与图 3 中的推理机制保持不变. 当多条规则同时被激发时, 会产生多个输出, 此时称为发生了冲突. 对冲突现象进行有效处理称为冲突消解. 对输出层的输出作进一步的处理, 可以达到冲突消解的目的.

设输出层的输出用两个向量表示为

$$C^{(2)} = [c_1^{(2)} \ c_2^{(2)} \ \dots \ c_n^{(2)}]^T \text{ 及 } C^{(2)'} = [c_1^{(2)'} \ c_2^{(2)'} \ \dots \ c_n^{(2)'}]^T,$$

其中:

$$c_i^{(2)} \in \{0, 1\}, \ c_i^{(2)'} \in R, \ i = 1, 2, \dots, n$$

则可对输出层的输出结果作如下处理: 将处理结果用向量  $O$  表示, 则  $O$  满足公式:  $O = C^{(2)} \cdot C^{(2)'}$ , 其中  $O$  的分量  $o_i$  满足公式  $o_i = c_i^{(2)} \times c_i^{(2)'}$ , 分量  $o_i$  表示第  $i$  条规则  $R_i$  根据证据的可信度向量  $P$  所推出的结论  $h_i$  的可信度  $CF(h_i)$ . 当  $o_i = 0$  时, 表示已知证据的可信度不足以激发规则  $R_i$ ; 当  $o_i = 1$  时, 表示已知证据的可信度激发了规则  $R_i$ , 且该规则所得结论的可信度等于  $o_i$ .

对于同一个证据的可信度向量  $P$ , 可能并行地激发多条规则进行不确定性推理, 并相应地得出每条规则所推出结论的可信度. 此时, 向量  $O$  中有多个分量不为 0. 这时可以针对不同的应用场合采用不同的冲突消解策略. 一条有效的策略是将获得最大分量的规则作为最终被采纳的规则; 另一种有效策略是设定一个规则的结论可接受的阈值  $\gamma$ , 只要向量  $O$  中与规则相应的分量大于阈值  $\gamma$ , 就接受该规则产生的结论, 否则, 拒绝该规则产生的结论.

### 3 结 语

1) 用神经网络不仅可以实现基于可信度的带权不确定性推理, 而且提高了自学习、并行推理、冲突消解等能力.

2) 文中采用的神经网络结构突破了传统神经网络结构的设计思想, 对于扩展神经网络的应用具有参考价值.

3) 如果证据的可信度及其权值, 以及规则的阈值不是用实数表示, 而是用模糊数表示, 则该神经网络结构可以改进为模糊神经网络结构, 这将是另一个具有意义的研究内容.

### 参考文献:

[ 1 ] 尹朝庆, 尹皓. 人工智能与专家系统 [M]. 北京: 中国水利水电出版社, 2002

[ 2 ] LAURITZEN S L, SPIEGELHALTER D J. Local computations with probabilities on graphical structures and their applications to expert system [ J ]. J R Statist Soc 1988 B 50: 157 - 224

[ 3 ] ZADEH L A. Fuzzy sets as a basis for a theory of possibility [ J ]. Int J of Fuzzy Sets and Systems 1975 1 ( 1 ): 199 - 249.

[ 4 ] SHORTLIFFE E H, BAUCHANAN B G. A method of inexact reasoning in medicine [ J ]. Math Biosci 1975 23: 351 - 379.

[ 5 ] ANDERSON J A, RONSENFELD E. Neurocomputing Foundations of Research [ M ]. Cambridge MA: MIT Press 1989.

[ 6 ] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back propagating errors [ J ]. Nature 1986 323: 533 - 36.

[ 7 ] HAGAN M T, DEMUTH H B, BEALE M H. Neural Network Design [ M ]. 戴葵等译. 北京: 机械工业出版社, 2002

(编辑 杨 波)