

# 一种基于功能性观点的神经网络规则提取方法\*

陈 果

(南京航空航天大学 民航学院 南京 210016)

**摘 要** 研究一种基于功能性观点的神经网络规则提取方法. 阐述特征排序与选择、连续属性离散化、训练样本产生、神经网络训练、示例样本产生及规则提取等关键算法. 并用 UCI 数据和人群分类数据对方法进行分析和验证. 结果表明本文方法的正确有效性.

**关键词** 神经网络(NN), 规则提取, 机器学习, 专家系统

**中图法分类号** TP 183; TP 391; TH 17

## Method for Rule Extraction from Neural Networks Based on Functional Point of View

CHEN Guo

(College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

### ABSTRACT

A method for rule extraction from neural networks based on the functional point of view is studied. The key algorithms are introduced, including the sort and selection of features, the discretization of continuous attributes, the generation of training samples of neural network (NN), the training of NN, the generation of the instance samples from the trained NN, and the rule extraction. The UCI data and the population classifying data are used to verify the rule extraction method. The results show the correction and effectivity of the proposed method.

**Key Words** Neural Network (NN), Rule Extraction, Machine Learning, Expert System

## 1 引 言

神经网络具有优越的非线性映射能力和容错性, 目前广泛应用于模式识别、机器学习、专家系统等领域<sup>[1-2]</sup>. 然而, 神经网络方法存在一个固有的缺陷, 即由于其获取的知识蕴涵在大量的连接权中难

以理解, 也难以推理过程给出清晰的解释, 严重限制了神经网络在机器学习和知识获取领域的发展. 因此, 需要从训练好的神经网络中提取知识规则, 这也是神经网络智能诊断和神经网络专家系统的迫切需求. 目前国内外学者对神经网络规则提取进行了大量的研究, Gallant<sup>[3]</sup>率先开展此方面研究, 他基于

\* 国家自然科学基金(No. 50705042)、航空科学基金(No. 2007ZB52022)资助项目

收稿日期: 2007-08-14; 修回日期: 2008-03-24

作者简介 陈果, 男, 1972 年生, 教授, 博士生导师, 主要研究方向为航空发动机状态监测与故障诊断、智能诊断与专家系统、机器学习与知识获取、图像处理及模式识别、非线性转子动力学等. E-mail: cgzyx@263.net.

推理强度对可用属性进行排序,从而构造出可解释网络如何为某个给定事例产生结论的规则. K. Saito<sup>[4]</sup>令网络输入逐渐改变,通过检查网络的激活度来构造候选规则集并从中寻找有用的规则. Fu<sup>[5]</sup>搜索结点的扇入连接权,通过找出权值之和超过阈值的连接权子集来抽取规则.

与结构分析方法不同,基于功能性分析的神经网络规则提取方法并不对神经网络结构进行分析和搜索,而是把神经网络作为一个整体来处理,即把神经网络看成“黑箱”.这类方法更注重的是抽取的规则在功能上对神经网络的重现能力.

通常,用训练好的神经网络对一个示例的输入模式进行判别,并将其判别结果作为输出模式,则与该输入模式一起组成一个完整示例.显然,该示例就在一定程度上反映了网络在示例空间中该点上的响应特性,如果这种示例数目足够多,并且较均匀地覆盖整个示例空间,则从该示例集中抽取的规则将具有与原神经网络相似的使用效果,即这些规则可以描述原网络的功能.这就是基于功能性观点的神经网络规则提取原理.

周志华等人<sup>[6]</sup>从功能观点出发,提出一种统计的神经网络规则提取方法,抽取出可理解性好、简洁、紧凑、保真度高的符号规则.他所提出的基于统计的神经网络规则抽取方法尽管在应用中取得较好效果,但是该方法的复杂性较高,且在使用过程中需要进行人为干涉,难于实现规则的自动提取.主要表现在两方面:1)在对连续属性的离散化处理中,寻找聚类效果好的属性进行离散化,这本身就是较困难且难于用计算机自动实现的问题;2)在神经网络训练中,神经网络本身的泛化能力优劣也往往依靠人为判断.

鉴于此,本文在研究现有基于功能性观点的神经网络规则提取方法的基础上,通过引入粗糙集理论及数据挖掘中的相关方法,提出一种神经网络规则提取方法,以期利用神经网络的泛化能力提取出高精度的规则.在特征选取中,引入数据挖掘中广泛应用的熵法.在连续属性离散化中,引入粗糙集理论中的由 S. H. Nguyen 和 Skowron 提出的布尔逻辑与粗糙集理论相结合的经典离散化方法.该方法可将离散属性看作连续属性的特例,同时进行处理,这在很大程度上降低计算的复杂性.在神经网络结构设计中,引入结构自适应神经网络模型,实现神经网络结构自动优化,以保证训练好的神经网络具有最佳的泛化能力.同时,整个优化过程能够自动完成.在规则提取中,提出一种分层穷举式的规则提取方

法,保证规则提取的完整性和优先次序.

## 2 神经网络规则提取方法的关键技术

### 2.1 特征排序与选取<sup>[7]</sup>

特征排序与选择对于减少数据特征的冗余、降低计算的复杂程度以及提高计算效率具有重要意义,本文将特征排序与选取作为神经网络规则提取的第一步,首先根据数据特征重要性排序,然后依据排序结果,对特征进行适当删减.

从信息论中可以知道,熵是一个全局变量,它对于有序结构较小,无序结构较大.因此,对特征移除前后的已知数据集的熵进行比较.如果两个度量接近,则该属性的重要性很小,归约后的特征集将较满意地接近原始集.对一个  $N$  个样本的数据集来说,熵为

$$E = - \sum_{i=1}^{N-1} \sum_{j=i+1}^N [S_{ij} \times \log S_{ij} + (1 - S_{ij}) \times \log(1 - S_{ij})],$$

其中  $S_{ij}$  是样本  $X_i$  和  $X_j$  的相似性.本文将离散型特征的取值变换为整数,因此两个样本间的相似性度量  $S$  的计算可统一定义为  $S_{ij} = \exp(-\alpha D_{ij})$ ,其中,  $D_{ij}$  是样本  $X_i$  和  $X_j$  间的距离,  $\alpha$  是一个参数,其数学表达式为

$$\alpha = - \frac{\ln 0.5}{D}$$

$D$  是数据集中样本间的平均距离.因此,  $\alpha$  由全部数据决定.通常,  $\alpha = 0.5$ .标准化的欧氏距离度量用于计算样本  $X_i$  和  $X_j$  间的距离  $D_{ij}$ :

$$D_{ij} = \left[ \sum_{k=1}^n \left( \frac{X_{ik} - X_{jk}}{\max_k - \min_k} \right)^2 \right]^{1/2},$$

其中,  $n$  是维数,  $\max_k$  和  $\min_k$  是用于第  $k$  维的最大和最小值.

基于熵法的特征排序和选取方法是通过逐步去除最不重要的特征并保持数据结构的有序性来排列特征.算法的步骤如下.

step 1 从初始的特征全集  $F$  开始.

step 2 对每个特征  $f_k \in F$ , 从  $F$  中去除一个特征  $f_k$ , 得到一个子集  $F_{f_k}$ . 找出  $F$  的熵和所有  $F_{f_k}$ ,  $k = 1, 2, \dots, n$ , 的熵之间的差.

step 3 将

$$(E_F - E_{F-f_1}), (E_F - E_{F-f_2}), \dots, (E_F - E_{F-f_n})$$

作为特征重要性指标.显然,如果特征越重要,去除后,集合的熵将变化很大,因此,特征重要性指标值

也越大.由此可见,可根据特征重要性指标对特征进行排序.规定一个适当的阈值,当特征重要性指标小于阈值时,即可将该特征从集合  $F$  中删除,从而实现特征选取.

## 2.2 连续属性离散化

从处理连续属性的神经网络中抽取规则是一个非常困难的问题,目前还未完全解决.如果不对连续属性进行离散化处理,以类似于回归树的方式进行反复的区间切分,则会由于连续属性取值空间的广大而陷入组合爆炸.因此,适当的离散化处理是必需的.

由于粗糙集理论<sup>[8]</sup>不需要先验知识便可完全从数据或经验中获取知识.因此,本文引入粗糙集理论中的离散化理论,在粗糙集理论中,连续属性的离散化处理可定义如下.

设决策表  $S = \{U, R, V, f\}$ ,  $R = C \cup \{d\}$  是属性集合,子集  $C$  和  $\{d\}$  分别称为条件属性集和决策属性集,  $U = \{x_1, x_2, \dots, x_n\}$  是有限的对象集合即论域.设决策种类的个数为  $r(d)$ .属性  $a$  的值域  $V_a$  上的一个断点可以记为  $(a, c)$ ,其中  $a, c \in \mathbf{R}$ .在值域  $V_a = [l_a, r_a]$  上的任意一个断点集合  $\{(a, c_0^a), (a, c_1^a), \dots, (a, c_{k_a}^a)\}$  定义了  $V_a$  上的一个分类  $P_a$ :

$$P_a = \{[c_0^a, c_1^a], [c_1^a, c_2^a], \dots, [c_{k_a}^a, c_{k_a+1}^a]\},$$

$$l_a = c_0^a < c_1^a < c_2^a < \dots < c_{k_a}^a < c_{k_a+1}^a = r_a,$$

$$V_a = [c_0^a, c_1^a] \cup [c_1^a, c_2^a] \cup \dots \cup [c_{k_a}^a, c_{k_a+1}^a].$$

因此,任意的  $P = \bigcup_{a \in \mathbf{R}} P_a$  定义了一个新的决策表

$S^p = (U, R, V^p, f^p)$ ,  $f^p(x_a) = i \Leftrightarrow f(x_a) \in [c_i^a, c_{i+1}^a)$ , 对于  $x \in U, i \in \{0, \dots, k_a\}$ ,即经过离散化后,原来的信息系统被一个新的信息系统所代替.

离散化本质上可归结为利用选取的断点来对条件属性构成的空间进行划分的问题.目前许多离散化方法,如等距离法<sup>[9]</sup>、等频率法<sup>[9]</sup>、 $L$ -方法<sup>[10]</sup>、 $W$ -方法<sup>[10]</sup>、 $P$ -方法<sup>[10]</sup>和  $C$ -方法<sup>[10]</sup>等,由于仅考虑单个属性,经过离散化后,可能引入冲突.而由 S. H. Nguyen 和 Skowron 提出的布尔逻辑与粗糙集理论相结合的离散化方法<sup>[11]</sup>,是粗糙集理论中离散化思想的重大突破.其基本思想是首先在保持信息系统的不可分辨关系不变的前提下,尽量以最小数目的断点把所有实例的分辨关系区分开,因此,离散化后数据集不会引入冲突.由于求最小数目的断点集是 NP 完全问题,因此只能寻找近似最优的算法来求得最小数目的断点集.在文献<sup>[11]</sup>中, S. H. Nguyen 和 Skowron 采用启发式算法(贪心算法)来求得最小数目的断点集.此算法基本步骤如下.

step 1 根据原来的信息表  $S = \{U, R, V, f\}$ , 构造一个信息表  $S^* = \{U^*, R^*, V^*, f^*\}$ , 其中

$$U^* = \{(x_i, x_j) \in U \times U \mid d(x_i) \neq d(x_j)\};$$

$$R^* = \{P_r^a \mid a \in C\}, P_r^a \text{ 是属性 } a \text{ 的第 } r \text{ 个断点}(c_r^a, c_{r+1}^a).$$

对于任意  $P_r^a$ , 如果  $[c_r^a, c_{r+1}^a] \subseteq [\min(a(x_i), a(x_j)), \max(a(x_i), a(x_j))]$ , 那么  $P_r^a((x_i, x_j)) = 1$ ; 否则,  $P_r^a((x_i, x_j)) = 0$ .

step 2 初始化最佳断点集  $CUT = \emptyset$ .

step 3 选取信息表  $S^*$  所有列中 1 的个数最多的断点加入到  $CUT$  中,去掉此断点所在的列和在此断点上值为 1 的所有行.

step 4 如果信息表  $S^*$  不为空,则转 step 3; 否则停止.此时,  $CUT$  即是所求的断点集.

## 2.3 训练样本产生

为了提高神经网络的泛化能力,通常对训练样本要增加一定的噪声.设噪声强度为信号的 10%, 训练样本有  $k$  个特征,一共有  $N$  个样本,则如果每个样本产生  $M$  个样本,则一共将产生  $M \times N$  个样本.本文方法如下.

step 1 对第  $i$  个样本.

step 2 第  $j$  个特征.

step 3 产生 0-1 分布的随机噪声,叠加到第  $i$  个样本、第  $j$  个特征值上,  $j$  从  $1 \sim k$  重复  $k$  次,即形成一个新的样本,再将该操作重复  $M$  次,则得到  $M$  个样本.

step 4  $i = i + 1$ , 转至 step 1, 直到  $i = N$ , 结束.最终产生  $M \times N$  个规定噪声强度的样本.

## 2.4 神经网络训练

在基于神经网络的知识获取和规则提取研究中,针对具体的样本数据,设计出具有最大泛化能力的最优网络结构至关重要.本文引用文献<sup>[12]</sup>中提出一种结构自适应神经网络模型,能够从给定样本中自动设计出具有最佳泛化能力的神经网络模型.

以三层 BP 网络为研究对象.将神经网络模型分为外部结构参数和内部权值参数,规定:1) 内部参数.网络连接权值,由 BP 算法对神经网络进行训练后自动产生.2) 外部参数.① 初始权值.影响网络的收敛位置;② 隐层节点数.直接影响到所逼近的非线性函数复杂程度和模型的泛化能力;③ 训练步数.对网络泛化能力具有很大的影响,网络训练步数越多,网络结构越复杂,泛化能力往往将变得很差.

结构自适应神经网络模型的基本思想如下.首先,在原始样本集合的基础上,通过加随机噪声的方法,得到训练样本集和测试样本集,在给定神经网络模型初始外部结构参数的情况下,利用神经网络的

BP 算法对训练样本集进行学习,获取模型的内部连接权值参数.再利用测试样本集,对学习模型进行测试,并计算识别误差,形成遗传算法的适应度函数.然后运用遗传算法的学习机制,自动调节神经网络模型的外部结构参数,在新的外部结构参数下,应用神经网络 BP 算法得到模型新的内部连接权值参数,按同样方法计算识别误差和适应度值,再进行下一步调整,直到达到遗传算法停止条件.最后输出具有最优泛化能力的神经网络模型.整个学习过程均自动完成.

在具体训练过程中,首先,在样本集中对  $N$  个样本迭加 10% 的随机噪声,每个样本产生  $M$  个新的样本,一共产生  $M \times N$  个新样本.形成神经网络训练集.按同样方法得到  $M \times N$  个新样本作为测试集.在结构自适应神经网络中,训练集用于对神经网络进行训练以获取网络内部参数,测试集用来测试网络的泛化能力,并以测试集的认识率计算适应度值.

本文遗传算法参数如下.种群数  $n = 10$ ,基因串(染色体)采用二进制编码,交叉率和变异率分别为 0.50 和 0.05,进化代数 10 代.隐层节点数用 3 位二进制编码,随机种子和最大训练步数均用 5 位二进制编码,规定解码后,隐层节点数加上 2,最大训练步数加上 1,随机种子乘上 10.适应度函数取为  $f = 1/N_{\text{error}}$ ,其中  $N_{\text{error}}$  为测试样本中被错误或无法识别的样本数.

### 2.5 示例样本产生<sup>[13]</sup>

通过优化后获取的神经网络模型应该具有较强的泛化能力,因此,如果用原始数据集训练出一个神经网络,再利用该神经网络产生一个数据集,则该数据集将比原始的数据集包含更多的有助于预测的信息.假设现有一个训练好的神经网络 ANN,如果用 ANN 对输入模式  $A_k = (a_1, a_2, \dots, a_n)$  进行判别,则神经网络将产生与  $A_k$  对应的输出模式  $C_k = (c_1, c_2, \dots, c_q)$ ,其中,  $n$  为输入属性数,  $q$  为输出分类数.将  $A_k$  和  $C_k$  组合起来就可得到一个示例样本  $(A_k, C_k)$ ,如果有很多这样的示例样本,就得到了一个示例样本集.

示例样本的具体产生方法如下.首先确定输入属性的取值范围,然后在该范围内生成一个随机数据集,原始的训练集也被加入到该数据集中.然后,由训练好的神经网络对该数据集进行判别,以产生相应的输出.最后再将输入和输出进行结合即得到规则学习部分所用的示例样本.实验结果表明,当随机数据集的个数为原样本数的 5 倍,可获得相当好的规则.由于这个实例集是由神经网络产生的,所

以实例集能体现神经网络的分类功能.

### 2.6 规则提取

为了从数据中提取出更多地满足一定可信度的知识规则,同时规则具有更大的适应性(即泛化能力),本文提出分层穷举式规则提取方法.该方法的基本思想是以规则条件数最少为启发知识,按属性数目由少到多进行分层,在每层中进行穷举组合提取知识规则.算法的具体描述如下.

**输入** 决策表  $S = \langle U, R, V, f \rangle$ , 其中,  $U$  是论域,  $R = C \cup \{d\}$  是属性集合,子集  $C$  和  $\{d\}$  分别称为条件和决策属性集,条件属性数目为  $m$ ,决策属性数目为 1,实例数为  $N$ ,可信度阈值为  $T$  和相对覆盖度阈值  $F$ ,条件属性数目  $N_{\text{MAX}}$ .

**输出** 可信度大于  $T$  且相对覆盖度大于  $F$  的规则集.

step 1 条件属性数  $NC$  从 1 开始到  $N_{\text{MAX}}$  进行下列循环计算.

step 2 在第  $NC$  层,首先进行属性组合,属性组合的数目为  $C_m^{NC}$ ,设  $c_{i_1} \dots c_{i_{NC}}$  为第  $i$  个属性组合,  $i = 1, 2, \dots, C_m^{NC}$ .令  $C^* = \{c_{i_1}, \dots, c_{i_{NC}}\}$ ,即条件属性集  $C^*$  对决策表  $S$  的划分  $E_{(K, C^*)}$ ,其中  $E_{(K, C^*)}$  属于  $U \mid \text{IND}(C^*)$ ,  $K = 1, \dots, \mid U \mid \text{IND}(C^*) \mid$ .

如果某个划分  $E_{(K, C^*)}$  对特定决策(如  $X_j$ ) 的可信度超过给定阈值  $T$ ,即

$$\mu_{C^*}(E_{(K, C^*)}, X_j) = \frac{\mid E_{(K, C^*)} \cap X_j \mid}{\mid E_{(K, C^*)} \mid} \geq T,$$

则得到规则

$\text{Des}(E_{(K, C^*)}, C^*) \rightarrow \text{Des}(X_j, D) \mid (\mid E_{(K, C^*)} \cap X_j \mid, \mid E_{(K, C^*)} \mid)$ ,其中,  $\mid E_{(K, C^*)} \cap X_j \mid$  为该规则在决策表中的绝对覆盖度,表示决策表中同时满足该规则前件和后件的实例数;  $\mid E_{(K, C^*)} \mid$  为决策表中满足该规则前件的实例数;  $\mid E_{(K, C^*)} \cap X_j \mid / \mid E_{(K, C^*)} \mid$  为该规则的可信度.

step 3 设示例样本总数为  $N$ ,则定义  $\mid E_{(K, C^*)} \cap X_j \mid / N$  为该规则在决策表中的相对覆盖度.如果相对覆盖度大于给定的阈值  $F$ ,则该规则有效,否则规则无效,即该规则不放入规则集合中.本文设定  $T = 0.9, F = 0.02$ .

step 4 将原始决策表  $S$  中满足该条规则前件的实例删除,得到新的决策表  $S' = \langle U', R, V, f \rangle$ ,如果  $U' = \emptyset$ ,则转入 step 5,否则,令  $S = S', NC = NC + 1$ ,如果  $NC > N_{\text{MAX}}$ ,则转入 step 5.否则转入 step 2.

step 5 输出所有规则集,计算结束.

### 3 本文方法验证

#### 3.1 规则提取的精度分析

本文目的是利用神经网络的泛化能力,从数据中提取出高精度的规则,因此,为了验证本文方法的有效性,本文利用国际上权威的 UCI 机器学习数据库中的 6 个数据集对本文算法进行实验测试. 实验中采用目前最流行的 10 折交叉验证准则来比较和评价算法,即将初始样本集划分为 10 个近似相等的子集,每个子集中属于各分类的样本所占的比例与初始样本中的比例相同,在每次实验中用其中的 9 个子集组成训练样本,用剩下的 1 个子集作为测试集,轮转 1 遍进行 10 次实验. 实验结

果如表 1 所示.

为了进行比较,本文利用相同的数据集,也对粗糙集理论的规则提取方法进行了 10 折交叉验证测试. 实验结果如表 2 所示. 在粗糙集算法中,对连续属性的离散化算法均采用文献[11]的贪心算法,属性约简均采用文献[9]的辨识矩阵法进行. 在规则提取中,分别采用文献[14]的启发式值约简方法(表 2 中的 M1)、文献[15]的归纳值约简方法(表 2 中的 M2)以及本文的分层穷举式方法(表 2 中的 M3). 表 3 为利用决策树 ID3 算法<sup>[7]</sup>对相同数据集进行规则提取,并进行 10 折交叉验证的结果,其中,在 ID3 算法,对连续属性的离散化处理仍采用文献[11]的贪心算法.

表 1 本文方法对 UCI 机器学习数据的 10 折交叉验证结果

Table 1 10-fold cross validity results for UCI machine learning data by proposed method

数据集	10 折交叉验证的识别率										
	1 折	2 折	3 折	4 折	5 折	6 折	7 折	8 折	9 折	10 折	平均
Iris	1.00	1.00	1.00	0.93	0.94	0.94	0.71	0.90	1.00	1.00	0.94
ACT	0.92	1.00	0.88	0.83	0.76	0.88	1.00	0.80	0.83	0.94	0.88
hepatitis	0.71	0.77	0.76	0.86	0.84	0.88	0.92	0.80	0.75	0.73	0.80
Ecoli	0.77	0.67	0.97	0.62	0.80	0.76	0.88	0.78	0.83	0.81	0.79
Glass	0.59	0.72	0.65	0.48	0.61	0.79	0.74	0.60	0.44	0.62	0.62
HSV	0.67	0.64	0.79	0.78	0.64	0.54	0.69	0.80	0.40	0.69	0.66

表 2 粗糙集方法对 UCI 机器学习数据的 10 折交叉验证结果

Table 2 10-fold cross validity results for UCI machine learning data by rough set methods

数据集		10 折交叉验证的识别率										
		1 折	2 折	3 折	4 折	5 折	6 折	7 折	8 折	9 折	10 折	平均
Iris	M1	0.79	1.00	1.00	0.86	0.94	1.00	0.71	0.90	1.00	1.00	0.92
	M2	0.86	1.00	1.00	0.86	0.94	1.00	0.71	0.90	1.00	1.00	0.93
	M3	0.86	1.00	1.00	0.86	0.94	1.00	0.71	0.90	1.00	1.00	0.93
ACT	M1	0.54	0.58	0.88	0.33	0.35	0.44	0.62	0.60	0.25	0.22	0.48
	M2	0.92	0.83	0.88	0.42	0.65	0.63	1.00	0.50	0.67	0.83	0.73
	M3	0.85	0.83	0.88	0.58	0.65	0.81	1.00	0.80	0.75	0.83	0.80
hepatitis	M1	0.50	0.38	0.52	0.57	0.58	0.59	0.50	0.70	0.58	0.55	0.55
	M2	0.71	0.38	0.67	0.79	0.74	0.53	0.79	0.80	0.58	0.82	0.68
	M3	0.79	0.77	0.67	0.86	0.84	0.76	0.79	0.80	0.67	0.82	0.78
Ecoli	M1	0.46	0.58	0.43	0.35	0.46	0.48	0.63	0.33	0.50	0.44	0.47
	M2	0.29	0.33	0.70	0.26	0.30	0.59	0.38	0.33	0.33	0.39	0.39
	M3	0.63	0.67	0.70	0.44	0.68	0.72	0.78	0.67	0.50	0.69	0.65
Glass	M1	0.27	0.28	0.35	0.26	0.32	0.42	0.68	0.13	0.28	0.42	0.34
	M2	0.23	0.11	0.23	0.26	0.25	0.32	0.16	0.20	0.06	0.31	0.21
	M3	0.45	0.61	0.62	0.39	0.50	0.53	0.53	0.33	0.44	0.42	0.48
HSV	M1	0.42	0.27	0.36	0.33	0.43	0.23	0.31	0.50	0.30	0.25	0.34
	M2	0.50	0.27	0.43	0.33	0.36	0.31	0.54	0.60	0.30	0.31	0.40
	M3	0.58	0.36	0.50	0.44	0.43	0.38	0.38	0.60	0.30	0.50	0.45

表3 决策树 ID3 算法对 UCI 机器学习数据的 10 折交叉验证结果

Table 3 10-fold cross validity results for UCI machine learning data by decision tree ID3 method

数据集	10 折交叉验证的识别率										
	1 折	2 折	3 折	4 折	5 折	6 折	7 折	8 折	9 折	10 折	平均
Iris	0.79	0.92	0.95	0.86	0.89	0.94	0.71	0.90	1.00	0.89	0.89
ACT	0.69	0.83	0.71	0.58	0.65	0.75	0.77	0.70	0.58	0.78	0.70
hepatitis	0.64	0.69	0.67	0.93	0.63	0.65	0.57	0.80	0.58	0.77	0.69
Ecoli	0.60	0.61	0.63	0.56	0.66	0.66	0.72	0.56	0.70	0.61	0.63
Glass	0.32	0.22	0.42	0.35	0.29	0.10	0.26	0.27	0.22	0.12	0.26
HSV	0.50	0.27	0.36	0.56	0.50	0.38	0.38	0.60	0.40	0.44	0.44

从表 1 ~ 表 3 的实验结果,通过比较分析可得以下结论.

1) 神经网络规则提取方法,充分利用了神经网络的泛化能力,因此,从训练好的神经网络中产生出的示例样本中提取出的规则也将更好地描述和表达原始数据集的知识信息.从表 1 ~ 表 3 的实验结果可看出,对于相同的数据集,神经网络规则提取方法得到的规则集具有更高的精度.值得注意的是,在表 2 的粗糙集规则提取方法中,采用本文分层穷举式方法得到的规则,其 10 折交叉验证的平均识别率均比本文神经网络方法提取出的规则要低,由于两种方法的离散化方法和规则提取方法均相同,故更具可比性.显然,结果进一步表明神经网络泛化能力能够保证提取出高精度的规则.由此可见,实验结果充分验证本文方法的有效性.

2) 从表 2 中可以看出,对于相同的数据集,对比文献[14]的启发式值约简方法和文献[15]的归纳值约简方法,利用本文的分层穷举式规则提取方法得到的规则集具有更高的精度,分层穷举式规则提取方法能够从数据集中提取和挖掘出更多的知识规则来,与其他方法相比,所提取的规则更加完整和准确.因此,该比较结果也充分验证了本文方法的正确有效性.

### 3.2 神经网络规则提取过程分析

利用文献[16]的人群分类数据,对本文基于功能性观点的神经网络规则提取算法过程进行分析.该实例集有 4 个特征,其中,2 个离散属性,即属性 A1: Hair (blond, red, dark, gray), 属性 A2: Eye (blue, brown, dark); 两个连续属性,即属性 A3: Height; 属性 A4: Weight. 该实例集有 3 类人群 Race, 即 1 为 white; 2 为 Black; 3 为 Yellow.

运用熵法对人群分类数据的属性排序结果,按属性重要性从高到低排列为 A4(=35.480)、A2(=25.471)、A1(=22.557)、A3(=5.151). 表明 A3 的重要性最低,故可以删除.因此,本文用两种不同的

属性组合来分别进行规则提取与验证实验,即属性组合 1: A1-A2-A3-A4、属性组合 2: A4-A2-A1. 表 4 为不同属性组合下的数据离散化结果.从表中可以看出,两种属性组合下的数据离散化结果差别很大,每个属性的断点值和断点数均不相同.从表 4 中可以看出,在属性组合 2 中,属性 A2 (eye) 为离散属性,取值为 1 (blue), 2 (brown), 3 (dark). 断点 2.5 表明取在 2 和 3 之间,其中 1 和 2 为一类,3 为另一类.由此可见,本文的离散化方法不区分连续属性和离散属性,不仅可大大简化问题,同时也非常容易理解.表 5 为不同属性组合下,通过结构自适应神经网络得到的最优神经网络结构参数.

表4 离散化断点结果

Table 4 Results of discrete cuts

属性组合	属性组合 1				属性组合 2		
	属性	A1	A2	A3	A4	A2	A1
断点值	—	—	169, 187	—	65, 102.5	2.5	—

表5 不同属性组合下得到的最优神经网络结构参数

Table 5 Optimum structure parameters of NN with different attribute combinations

属性组合	输入层节点数	中间层节点数	最大训练步数	权值随机种子	训练误差
属性组合 1	4	2	30	30	0.001
属性组合 2	3	2	30	30	0.001

用本文分层穷举式的规则提取方法,根据属性组合 1 和属性组合 2 分别得到规则集如表 6 所示.对原始样本集引入 10% 的随机噪声,形成 320 个测试样本,表 7 为利用所提取的规则对测试样本的识别结果.从所提取的规则可以发现,对于属性组合 1,仅通过“Height”即可对人群进行识别,因此规则前件最少,规则条数为 3,对测试集的识别率为 81.3%.对于属性组合 2,利用了“Eye”和“Weight”两个属性对人群进行识别,其中规则条数为 4,对测

试集的认识率为 87.5%。由此可见,不同的属性组合所提取出的规则差别较大,但对测试集的认识率均达到 80% 以上。

表 6 2 种属性组合得到的规则集

Table 6 Extraction rules by 2 attribute combinations

属性组合 1	属性组合 2
R1: (187 < Height < 220) ⇒white	R1: (42.5 < Weight < 65) ⇒Yellow
R2: (132 < Height < 169) ⇒Yellow	R2: (102.5 < Weight < 125) ⇒white
R3: (169 < Height < 187) ⇒Black	R3: (65 < Weight < 102.5) AND( Eye = blue OR Eye = brown)⇒white
—	R4: (65 < Weight < 102.5) AND( Eye = dark)⇒Black

表 7 规则验证结果

Table 7 Verification results of rules

属性组合	数据 个数	正确 数	错误 数	识别 率(%)	误识 率(%)	拒识 率(%)
属性组合 1	320	260	60	81.3	18.7	0
属性组合 2	320	280	40	87.5	12.5	0

## 4 结束语

针对目前基于功能性观点的神经网络规则提取方法所存在的连续属性离散化和神经网络结构优化问题,提出一种基于功能性观点的神经网络规则提取方法,阐述了特征排序与选取、连续属性的离散化处理、神经网络训练样本产生、神经网络结构优化、示例样本的产生以及规则提取等关键技术的理论与方法。用 UCI 机器学习数据和人群分类数据进行了分析和验证,并与粗糙集规则提取方法和决策树 ID3 算法进行比较分析,结果表明本文神经网络规则提取方法的有效性。

## 参 考 文 献

[1] Yu Heji, Chen Changzhen, Zhang Sheng, *et al.* Intelligent Diagnosis Based on Neural Network. Beijing, China: Metallurgical Industry Press, 2000 (in Chinese)  
(虞和济,陈长征,张省,等.基于神经网络的智能诊断.北京:冶金工业出版社,2000)

[2] Wu Jinpei, Xiao Jianhua. Intelligent Fault Diagnosis and Expert System. Beijing, China: Science Press, 1997 (in Chinese)  
(吴今培,肖建华.智能故障诊断与专家系统.北京:科学出版

社,1997)

- [3] Gallant S I. Connectionist Expert Systems. Communications of the ACM, 1988, 31(2): 152-169
- [4] Saito K, Nakano R. Medical Diagnostic Expert System Based on PDP Model // Proc of the IEEE International Conference on Neural Networks. San Diego, USA, 1988, 1: 255-262
- [5] Fu L M. Rule Learning by Searching on Adapt Nets // Proc of the 9th National Conference on Artificial Intelligence. Anaheim, USA, 1991: 590-595
- [6] Zhou Zhihua, He Jiashou, Yin Xuri, *et al.* A Statistics-Based Approach for Rule Extraction from Neural Networks. Journal of Software, 2001, 12(2): 263-269 (in Chinese)  
(周志华,何佳洲,尹旭日,等.一种基于统计的神经网络规则抽取方法.软件学报,2001,12(2): 263-269)
- [7] Kantardzic M. Data Mining Concepts, Models, Methods, and Algorithms. New York, USA: IEEE Press, 2002
- [8] Pawlak Z. Rough Set. International Journal of Information and Computer Science, 1982, 11(5): 341-356
- [9] Wang Guoyin. Rough Set Theory and Knowledge Acquisition. Xi'an, China, Xi'an Jiaotong University Press, 2001 (in Chinese)  
(王国胤.粗糙集理论与知识获取.西安:西安交通大学出版社,2001)
- [10] Ryszard N, Roman S, Jerzy S. Evaluation of Vibroacoustic Diagnostic Symptoms by Means of the Rough Sets Theory. Computers in Industry, 1992, 20(2): 141-152
- [11] Nguyen H S, Skowron A. Quantization of Real Values Attributes, Rough Set and Boolean Reasoning Approaches // Proc of the 2nd Joint Annual Conference on Information Science. Wrightsville Beach, USA, 1995: 34-37
- [12] Chen Guo. Structure Self-Adaptive Neural Network Model Realizing Structural Risk Minimization Principle. Chinese Journal of Scientific Instrument, 2007, 28(10): 1874-1879 (in Chinese)  
(陈果.一种实现结构风险最小化思想的结构自适应神经网络模型.仪器仪表学报,2007,28(10): 1874-1879)
- [13] Zhou Zihua, Jiang Yuan, Chen Shifu. Extracting Symbolic Rules from Trained Neural Network Ensembles. AI Communications, 2003, 16(1): 3-15
- [14] Chang Liyun, Wang Guoyin, Wu Yu. An Approach for Attribute Reduction and Rule Generation Based on Rough Set Theory. Journal of Software, 1999, 10(11): 1207-1211 (in Chinese)  
(常犁云,王国胤,吴渝.一种基于 Rough Set 理论的属性约简及规则提取方法.软件学报,1999,10(11): 1207-1211)
- [15] Wu Fubao, Li Qi, Song Wenzhong. Inductive Learning Approach to Knowledge Representation System Based on Rough Set Theory. Control and Decision, 1999, 14(3): 206-211 (in Chinese)  
(吴福保,李奇,宋文忠.基于粗糙理论知识表达系统的一种归纳学习方法.控制与决策,1999,14(3): 206-211)
- [16] Chen Zhaoqian, Liu Hong, Zhou Rong, *et al.* A Hybrid Algorithm for Multi-Concept Acquisition and Its Application. Chinese Journal of Computers, 1996, 19(10): 753-761 (in Chinese)  
(陈兆乾,刘宏,周戎,等.一种混合型多概念获取算法 HMCAP 及其应用.计算机学报,1996,19(10): 753-761)