

一种粗逻辑神经网络研究

张东波^{①②} 王耀南^①

^①(湖南大学电气与信息工程学院 长沙 410082)

^②(湘潭大学信息工程学院 湘潭 411105)

摘要: 该文基于粗逻辑理论,研究了粗逻辑意义下的粗集神经网络的设计,分析和比较了粗逻辑神经网络和模糊逻辑神经网络的性质。在重庆地区 Landsat TM 遥感图像的地物分类实验中,验证了粗逻辑神经网络的有效性,同时可以发现其在网络结构和收敛性方面的优势。

关键词: 粗糙集; 粗逻辑; 粗逻辑神经网络; 模糊逻辑神经网络

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2007)03-0611-05

The Research of a Kind of Rough Logic Neural Network

Zhang Dong-bo^{①②} Wang Yao-nan^①

^①(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

^②(Institute of Information Engineering, Xiangtan University, Xiangtan 411105, China)

Abstract: In this paper, based on rough logic theory, the design of rough neural network in the meaning of rough logic is studied. The character of rough logic neural network and fuzzy logic neural network are analyzed and compared. The validity of the rough logic neural network can be verified in the land cover classification experiment of the Landsat TM remote sensing image of Chongqing area. The rough logic neural network has superiorities at the aspect of structure and convergence.

Key words: Rough set; Rough logic; Rough Logic Neural Network(RLNN); Fuzzy Logic Neural Network(FLNN)

1 前言

粗糙集理论^[1, 2]是由波兰数学家Pawlak提出的一种对不确定、不完整、不精确知识进行处理的数学理论。该理论凭借强大的定性分析能力,已成为除模糊集、神经网络之外的一种新的有效的不确定性计算工具。在模式识别、机器学习、知识发现等领域得到广泛应用。但是,粗糙集本身抗噪声性能差,推广能力弱,在应用中往往需要与其它软计算方法如模糊集、神经网络进行集成。由于神经网络具有抗噪声性能好,泛化能力较强的特点,与粗糙集理论具有很强的互补优势;因此近年来,粗集理论与神经网络的集成技术得到了积极地研究。其中基于粗糙集决策规则的“强耦合”集成方式^[3]的粗集神经网络得到了广泛地应用^[4-7];但以往的粗集神经网络都是以单纯的粗糙集数据分析和约简为基础的,对其内在决策原理缺乏深入地阐述。粗逻辑^[8, 9]从逻辑学的观点,利用逻辑工具,对信息系统及粗推理决策进行研究,能够深入地揭示粗糙集理论的实质;因此,本文从粗逻辑的角度,研究了基于产生式决策规则的粗逻辑神经网络(Rough Logic Neural Network, RLNN)的设计。基于模糊决策规则的模糊逻辑神经网络(Fuzzy Logic Neural Network, FLNN)^[10, 11]是集成了模糊集和神经网络对模糊信息进行处

理的智能计算方法,已经在很多领域得到有效应用。由于RLNN和FLNN都是基于规则的神经网络,结构上非常类似,因此,文中对这两种神经网络进行了分析和比较,对RLNN的原理有了更深刻的认识。文中同时探讨了粗糙集理论和模糊集理论进行融合后,构造出模糊粗神经网络或粗模糊神经网络的可能。

2 粗逻辑与决策

已知一个信息系统 $S = (U, A)$, 信息系统如果以关系表的形式表示,则行对应要研究的对象,列对应对象的属性。当属性集 A 由条件属性集 C 和决策属性集 D 构成时, $C \cap D = \phi$, 此时信息系统对应的关系表称之为决策表。粗逻辑是一种基于粗糙集理论,通过逻辑的工具对决策表进行分析处理的理论,其基本概念和理论介绍如下。

2.1 粗逻辑语言与语义

粗逻辑语言由语言符号集构成,包括属性常量集 A ;属性值常量集 V , $V = \cup_{a \in A} V_a$;命题连接词集 $\{\sim, \vee, \wedge, \rightarrow, \equiv\}$;辅助符号,如括号 $()$ 。粗逻辑语言是一种命题语言,由属性-属性值形式的原子公式或复合公式来表示。 $\forall a \in A, v \in V_a$, 形如 (a, v) , 或简写为 a_v 的表达式称为原子公式。原子公式组合适当的命题连接词可以构成复合公式。

粗逻辑语言中的公式都具有一定的含义,可以表示论域中某些对象的集合,例如原子公式 (a, v) 表示对属性 a 取值为

2005-08-28 收到, 2006-03-08 改回

国家自然科学基金(60375001), 高等学校博士点基金(20030532004)和湖南省教育厅科研项目(05C093)资助课题

v 的对象集合。通过模型和可满足性可以精确地表达粗逻辑的语义,模型即为信息系统 $S = (U, A)$, 通过适当的解释,每一个公式都变成表达某些对象性质的有意义的语句。

对象 $x \in U$ 在模型 $S = (U, A)$ 中满足公式 ϕ , 记作 $x \models_s \phi$, 定义 $|\phi|_S = \{x \in U \mid x \models_s \phi\}$, $|\phi|_S$ 称为公式 ϕ 在 S 中的含义, 即所有满足公式 ϕ 的对象集合。

2.2 粗逻辑推演

给定信息系统 $S = (U, A)$, 属性集合 $P = \{a_1, \dots, a_n\}$, $P \subseteq A$ 。形如 $(a_1, v_1) \wedge (a_2, v_2) \wedge \dots \wedge (a_n, v_n)$ 的公式称为 P 基本公式, 如果 $P = A$, 则 A 基本公式可以简称为基本公式。

所有 S 中可满足的 P 基本公式称为 S 的基本知识, 记为 $\sum_s(P)$, 表示所有在 S 中可满足的 P 基本公式的析取。如果 $P = A$, 则 $\sum_s(A)$ 称为信息系统 S 的特征公式, 特征公式代表了信息系统 S 的全部知识。因为信息表的每一行都可以用一个基本公式来表示, 这使得用公式取代信息表来表示知识是可行的。

粗逻辑有如下特殊公理: (1) $(a, v) \wedge (a, u) \equiv 0$, $\forall a \in A, u, v \in V$ 且 $u \neq v$; (2) $\bigvee_{v \in V_a} (a, v) \equiv 1, \forall a \in A$; (3) $\sim(a, v) \equiv \bigvee_{u \in V_a, u \neq v} (a, u), \forall a \in A$ 。1 和 0 分别表示逻辑的“真”、“假”。

公式 ϕ 可以由公理及公式集 Ω 中的公式通过有限次应用推理规则导出, 记作 $\Omega \vdash \phi$ 。公式 ϕ 如果可以从公理集中导出, 则 ϕ 是粗逻辑的一个定理, 记作 $\vdash \phi$, 如果 ϕ 和 $\sim \phi$ 不能同时从 Ω 中导出, 则公式集 Ω 是相容的。给定信息系统, 在获得特征公式集的基础上, 结合经典命题演算系统的公理和粗逻辑的特殊公理, 即可实现粗逻辑推理。

2.3 决策规则与决策算法

任何一个蕴涵式 $\phi \rightarrow \psi$ 称为一个决策规则, ϕ, ψ 分别称为规则 $\phi \rightarrow \psi$ 的前件和后件, 如 $\phi \rightarrow \psi$ 在 S 中真, 则称 $\phi \rightarrow \psi$ 在 S 中是相容的, 否则, 称为不相容的。对决策规则 $\phi \rightarrow \psi$, 如果 ϕ 是一个 P 基本公式, ψ 是一个 Q 基本公式, 则称 $\phi \rightarrow \psi$ 是一个 PQ 基本决策规则。任何一个决策规则的有限集称为一个决策算法, 对应地, 任何一个基本决策规则的有限集称为一个基本决策算法, 仅包含 PQ 决策规则的算法称为 PQ 算法, 记作 (P, Q) 。

一个 PQ 决策算法中的规则 $\phi \rightarrow \psi$ 在 S 中是真的(相容的)当且仅当对任意该算法中的规则 $\phi' \rightarrow \psi'$, $\phi = \phi'$ 蕴涵 $\psi = \psi'$ 。在实际检验中, 若相同的前件具有不同的后件, 则这种规则是不相容的, 这通常作为检验规则是否相容的实际准则。

2.4 粗逻辑决策算法的简化

由于知识库中往往存在冗余和相关信息, 并非所有的知识都是必要的, 因此引出了知识约简的概念, 对于与知识信息系统对应的粗逻辑决策算法而言, 知识约简意味着粗逻辑决策算法的简化。

2.4.1 决策算法的约简 设 (P, Q) 是一个相容算法, $a \in P$, 当算法 $(P - \{a\}, Q)$ 相容时, 称属性 a 在 (P, Q) 中是可省的,

否则 a 是不可省的。如果 P 中所有属性都是不可省的, 则称算法 (P, Q) 是独立的, 对于 $R \subseteq P$, 当算法 (R, Q) 独立且相容时, 称 (R, Q) 为 (P, Q) 的一个约简, 算法的约简能去掉不必要的条件属性, 简化知识表达空间的维数。不相容算法的约简可以从去掉某些属性后正域的变化来求取, 具体见文献[8], 在此不再赘述。

2.4.2 决策规则的约简 利用决策逻辑分别消去决策算法中每一个决策规则的冗余属性值, 可以进一步简化决策算法。

若 ϕ 是一个 P 基本公式, $Q \subseteq P$, ϕ/Q 表示从 ϕ 中移去所有 (a, v_a) ($a \in P - Q$) 剩余的 Q 基本公式。设 $\phi \rightarrow \psi$ 是一个 PQ 规则, $a \in P$, 如果 $\models_s \phi \rightarrow \psi$ 蕴涵 $\models_s \phi / (P - \{a\}) \rightarrow \psi$, 则 a 在规则中是多余的, 否则, a 在该规则中是必要的, 如果任一 $a \in P$ 在该 PQ 规则中都是必要的, 则称该规则是独立的。 P 的子集 R 称为 PQ 规则 $\phi \rightarrow \psi$ 的一个约简, 如果 $\phi/R \rightarrow \psi$ 是独立的且 $\models_s \phi \rightarrow \psi$ 蕴涵 $\models_s \phi / R \rightarrow \psi$ 。

2.4.3 决策算法的极小化 一个决策算法中所有的决策规则并非都是必要的, 针对每一个决策类可以删除多余的决策规则, 删除这些规则后并不影响决策的制定, 去掉的规则的作用可以由留下来的规则完成。

设 $S = (U, A)$ 是一个信息系统, F 是一个基本算法, F_ψ 表示算法 F 中所有具有后件 ψ 的基本规则集合, P_ψ 表示 F_ψ 中所有规则的前件组成的集合。算法 F 中规则 $\phi \rightarrow \psi$ 是多余的, 如果 $\bigvee P_\psi = \bigvee (P_\psi - \{\phi\})$, 否则称该规则不是多余的。如果 F_ψ 中所有规则都不是多余的, 则称 F_ψ 是独立的。 F_ψ 的子集 F'_ψ 称为 F_ψ 的一个约简, 如果 F'_ψ 是独立的, 且 $\bigvee P_\psi = \bigvee P'_\psi$ 。决策规则集 F_ψ 称为既约的, 如果它是自身的一个约简。基本算法 F 称为极小的, 如果其中每一个规则是既约的且对每一个决策规则 $\phi \rightarrow \psi$, F_ψ 是既约的。

3 粗逻辑神经网络设计

3.1 粗逻辑决策算法的实现过程

粗逻辑推理的优势在于可以通过上述粗逻辑理论进行决策算法的简化, 为实际问题找到简捷高效的解法。具体实现步骤如下。

步骤 1 属性域知识编码 选择合适的条件属性和决策属性并对属性域进行离散编码, 常用的离散化方法有等间隔法、等频法、布尔逻辑推理方法、聚类方法^[12, 13]等。

步骤 2 知识获取 生成描述条件与决策属性之间关系的决策表, 决策表可以由实测和检验数据或专家经验知识来生成。决策表中数据的不相容也许意味着选择的条件属性过少或者等价类划分的知识颗粒过大, 根据实际情况可进行必要的改进。在保证知识点的分布合理的前提下, 生成初始决策表。

步骤 3 决策算法的简化 包括决策算法的约简(属性约简)、决策规则的约简、决策算法的极小化 3 个具体简化过程。

步骤 4 决策算法的实现 (构建相应粗逻辑神经网络) 从最简决策表中提取决策规则, 仿照模糊逻辑神经网络的结构, 构建相应粗逻辑神经网络, 在整合粗逻辑的决策能力和

神经网络的推广化能力的基础上，解决实际问题。

3.2 粗逻辑神经网络结构及学习

在已经获得的最小决策算法的基础上，类似于模糊逻辑神经网络^[10, 11]，构造如图 1 适用于模式分类的粗逻辑神经网络，网络总共由 4 层构成。




图 1 粗逻辑神经网络结构

第 1 层为输入层，输入向量 $x = (x_1, x_2, \dots, x_n)^T$, $x_i (i = 1, 2, \dots, n)$ 。

第 2 层为等价类分层，依据某种离散化方法，分别将输入变量 $x_i (i = 1, 2, \dots, n)$ 离散化为 r_i 个不同值，该层神经元激励函数可取为高斯函数：

$$\mu_i^j = \exp\left(-\frac{x_i - c_{ij}}{\delta_{ij}}\right)^2 \quad (1)$$

c_{ij} , δ_{ij} 分别是被划分化到第 $j (j = 1, 2, \dots, r_i)$ 档的变量 x_i 的类中心和方差，初始值由训练样本进行估算。

第 3 层为规则层，其中每一个节点代表一条规则，规则的获取和描述的理论依据是粗逻辑理论，该层神经元和第 2 层、第 4 层神经元的连接关系，由规则的前件和后件来决定，该层神经元本身完成规则的适应度计算，第 k 个神经元 R_k 的输出：

$$O_k^3 = \mu_1^{j_1} \cdot \mu_2^{j_2} \cdots \mu_n^{j_n} \quad (2)$$

其中 $\mu_1^{j_1}, \mu_2^{j_2}, \dots, \mu_n^{j_n}$ 表示与该节点连接的第 2 层节点的输出值， $j_1 \in \{1, 2, \dots, r_1\}$, $j_2 \in \{1, 2, \dots, r_2\}, \dots, j_n \in \{1, 2, \dots, r_n\}$, $k = 1, 2, \dots, s$, s 为规则数。

第 4 层为输出层，也是模式决策层，其输出：

$$y_c = O_c^4 = f_4\left(\sum_{l=1}^p w_{lc} O_l^3\right) \quad (3)$$

$c = 1, 2, \dots, C$, $l = 1, 2, \dots, p$, C 是决策类数， p 是与第 c 类相关的规则数， f_4 是输出层的激励函数，取为对数 S 函数 logsig。第 3 层和第 4 层神经元之间的连接权表示规则的合成算法，初始值可由规则的支持度来确定。

网络需调节的权值参数为 w_{lc} 及等价类分层的类中心 c_{ij} 与方差 δ_{ij} ，可由反向传播 BP 算法迭代来进行训练。RLNN 构建出来后，可能的需要解决的问题有如下两种。

(1)对于 RLNN 来说，知识的等价类划分对网络性能影响很大，而在设计 RLNN 时，这往往是事先给定的，存在较大的主观性，实际上很多情况下，等价类边界的确定并不是一件容易的事，因而影响到 RLNN 难以得到最优结果。为一定程度解决这一问题，可以考虑采用动态自适应算法从实例

中进行学习来实现等价类的合理划分。RLNN 中类中心 c_{ij} 与方差 δ_{ij} 在训练过程中的调整，为解决这一问题提供了可能。

(2)RLNN 在设计过程中，可能会得到不相容的决策规则，这是由于条件属性过少造成的，解决的途径之一是增加条件属性来获得相容的决策表，但这不一定可行，需要增加的属性也许是未知的，或者获取的代价过高，另外属性过多，造成网络规模和复杂程度大大增加。另外一种解决途径是直接从冲突数据本身给出的统计信息，进行均衡决策，这一程度可以通过调节第 3 层和第 4 层间的权值 w_{lc} 来实现。

RLNN 的训练过程，就是不断地调节其等价类划分(调节 c_{ij} , δ_{ij})和规则合成算法(调节 w_{lc})来实现模式分类。

3.3 粗逻辑神经网络与模糊逻辑神经网络的比较

粗逻辑神经网络和模糊逻辑神经网络具有类似的结构，均为基于产生式规则的决策算法，都是解决不精确问题实现近似决策的有效工具。但两者具有明显不同的特性，这主要体现在以下几个方面。

(1)RLNN 和 FLNN 分别基于粗糙集理论和模糊集理论，而粗糙集和模糊集处理是不确定知识的两个不同的侧面：不可分辨性和模糊性。模糊集处理的概念本身是模糊的，而粗糙集处理的概念本身是清晰的，不能精确表示是因为未获得足够的描述问题的知识。粗糙集解决问题的途径是从模式分类的观点出发，尽可能实现合理的等价类划分，并找寻到条件类与决策类之间的决策关系。而模糊集对论域进行的是模糊划分，形成的是模糊相似类，可以用语言变量表示的各模糊相似类之间没有明显的分界面，输入与输出之间的决策关系往往由专家给定，或从工程人员的实际操作中总结出来。

(2)基于粗逻辑的 RLNN，通过决策算法的约简，决策表的极小化，可以获得极为精简的决策算法，这是解决实际问题时所期望的重要特性，而这是 FLNN 所不具备的。通过知识约简，不仅可以去除不必要的条件属性，同时还能够估算出相应属性对分类的重要性，从而更深刻地洞察到问题的本质。

(3)对于 RLNN 来说，决策规则都是通过粗糙集数据分析从原始实验数据中提取的，不需要先验知识，而模糊规则往往是由实际操作人员或专家给定的，同时模糊隶属函数的确定也是人为的，因此 FLNN 的设计掺杂了更多的人为因素。

(4)FLNN 所表示的规则相对来说更直观且易于理解，因为模糊规则中直接采用模糊语言词汇来描述，而粗逻辑中输入变量的取值范围被分成若干不相交的区间，这些区间往往不能用合适的词汇来描述，造成一条模糊规则能够表达清楚的意义可能需要若干条粗糙规则才能表达出来。

(5)如果条件属性和决策属性均为离散变量，则 RLNN 是比 FLNN 更好的选择，如果条件属性和决策属性都是连续变量，而且难以离散化为合理的等价类形式，则采用 FLNN 的效果可能更好。

粗糙集和模糊集虽然从不同角度来处理不确定性信息，但两者并不对立，反而具有互补的关系^[14-16]，两者存在如下融合的可能。

(1)利用粗糙集技术简化模糊逻辑规则集,首先将模糊规则集(FLRS)转换为粗逻辑规则集(RLRS),粗逻辑规则集被约简后,通过逆变换,获得约简形式的模糊规则集,整个处理过程如图 2。




图 2 由粗糙集进行模糊逻辑决策规则约简的处理过程

(2)粗糙集中的等价关系如果被模糊相似关系取代,可以引出模糊粗糙集^[14, 15],如果用粗糙集来近似模糊集,则可以引出粗糙模糊集^[14, 16],这都是粗糙集和模糊集的信息集成形式,通过基于模糊粗糙集和粗糙模糊集理论下的决策算法,构造出的相应粗模糊决策网络,应该具有更强的综合信息处理能力。

4 遥感图像分类实验

选择重庆地区的 Landsat TM 遥感图像来进行实验,已知的一幅 586×650 的 7 波段图像,图像中部为城区,四周山川环绕,长江自西南向东北横贯城区,东部大巴山阴条岭为全市最高点,整个区域内,各类地物交错分布,适合作地物分类。

4.1 数据样本获取

通过目视解译,该地区地类主要分为 5 类,河流(d_1),山谷(d_2),植被(d_3),空地(d_4),建筑用地(d_5),总共抽取了 1750 个样本,其中 500 个样本作为训练样本,250 个样本作为校验样本,其余 1000 个样本作为测试样本。各类样本的期望输出编码为 $d_1(0.9, 0.1, 0.1, 0.1, 0.1)$, $d_2(0.1, 0.9, 0.1, 0.1, 0.1)$, $d_3(0.1, 0.1, 0.9, 0.1, 0.1)$, $d_4(0.1, 0.1, 0.1, 0.9, 0.1)$, $d_5(0.1, 0.1, 0.1, 0.1, 0.9)$ 。

4.2 基于粗逻辑的知识约简

首先提取出原始图像各波段数据,采用布尔逻辑方法进行数据的离散化^[13],构造出对应的决策表,在此基础上,分别进行决策算法简化的各项处理。

(1)决策算法约简(属性约简) 在这里,并非所有的波段数据对分类都是必要的,各波段数据中含有大量冗余信息,通过属性约简,可以确定波段 Band3, 4, 5 是它的一个约简,相应由约简属性构成简化的决策表。表 1 是约简属性的离散编码表。波段 Band3, 4, 5 分别用符号 a, b, c 表示,分别被离散化为 3 段, 5 段, 2 段。

(2)决策规则约简和决策算法的极小化 通过对每一条决策规则的分析,去掉规则的不必要条件属性,最后去掉重复多余的规则和不重要的规则(支持度过低的规则),得到仅由 10 条规则组成的一个相容的最简决策表,见表 2。其中规则支持度由本规则代表的样本数和该类别总的样本数的比值来决定。

4.3 粗逻辑神经网络设计、初始化和训练

根据决策算法约简的结果,即最简决策表,构建出相应的粗逻辑神经网络,输入层 3 个神经元,对应 3 个波段的数据;等价类划分层 10 个神经元,对应各波段的等价区间划分;规则层 10 个神经元,对应 10 条最简决策规则;输出层 5 个神经元,对应 5 类地物,根据规则即可确定各层神经元之间的连接关系。神经网络构建后,对其中需调节的参数进行初始化,其中,各等价类的中心 c_{ij} 和方差 δ_{ij} , 由训练样本进行估算后予以赋值,而 w_{ic} 则由规则的支持度(见表 2)赋初值。网络通过 BP 算法进行训练,为避免过学习,保证网络泛化能力,采用了常用的样本校验方法。校验样本是单独选出来检验神经网络的训练质量的,本身不参与训练,在训练过程中,训练误差逐步减小,但训练到一定程度时,尽管训练误差还可以进一步减小,但是对训练样本以外的校验样本分类性能可能会下降,这表示网络已经出现过学习,再训练下去,网络的泛化能力会下降,此时应终止训练。约经过 1000 次迭代训练,网络逐步收敛。

4.4 分类结果

网络训练后,对测试样本的分类结果,即误分类矩阵及各类别分类精度见表 3,整体分类精度达到 94.1%,具有良好的分类性能。图 3 是由约简的 3 个波段 Band3, 4, 5 合成的原始图像,图 4 是由 RLNN 处理后的分类图。

表 1 约简属性的离散编码表

属性编码	波段属性	属性值编码				
		0	1	2	3	4
a	Band3	$[-\infty, 46)$	$[46, 113)$	$[113, +\infty)$		
b	Band4	$[-\infty, 92)$	$[92, 111)$	$[111, 131)$	$[131, 153)$	$[153, +\infty)$
c	Band5	$[-\infty, 75)$	$[75, +\infty)$			

表 2 最简决策表

规则号	规则	规则支持度	规则号	规则	规则支持度
1	$a_0c_1 \rightarrow d_1$	1.00	6	$b_1c_0 \rightarrow d_3$	0.07
2	$a_0b_0 \rightarrow d_2$	1.00	7	$a_2b_4 \rightarrow d_4$	0.99
3	$b_4c_0 \rightarrow d_3$	0.24	8	$b_1c_1 \rightarrow d_5$	0.24
4	$b_3c_0 \rightarrow d_3$	0.47	9	$a_1b_0 \rightarrow d_5$	0.67
5	$b_2c_0 \rightarrow d_3$	0.22	10	$a_2b_2 \rightarrow d_5$	0.08

表3 测试样本分类结果

实际类别	RLNN 分类					分类精度
	d_1	d_2	d_3	d_4	d_5	
d_1	186	0	12	1	1	93.0%
d_2	0	198	0	0	2	99.0%
d_3	0	14	185	1	0	92.5%
d_4	1	0	4	194	1	97.0%
d_5	0	1	14	7	178	89.0%
全部样本						94.1%




图3 原始图像

图4 分类结果图

5 结束语

从本文的研究及遥感图像分类实验中，可以展现出 RLNN 网络的特点：

(1)通过粗逻辑理论对知识进行约简后，消除了大量的冗余信息，构建的粗逻辑神经网络具有结构精简，学习速度快的特点。

(2)类似于模糊逻辑神经网络，该网络模型具有清晰的语义结构，具有可解释性、透明性，可以给出问题求解的描述和过程。

(3)具有一定的容错能力，在数据不相容的情况下，可以进行决策并有较好的性能。

(4)RLNN 网络特别适用于条件属性、决策属性均为离散数据及缺乏先验知识的应用场合，在难以找到合适的模糊决策规则集时，不依赖于先验知识的 RLNN 也是一种很好的选择。

本文所做的研究工作还很有限，在今后的研究中，仍存在许多有待改进和进一步探讨的地方，如：

(1)RLNN 的性能在很大程度上取决于等价类划分，划分的粒度越小，计算精度越高，但同时网络结构复杂化，计算量及训练时间也会大大增加。如何在这些因素之间取得一个较好的平衡仍是一个有待研究的问题。

(2)粗糙集和模糊集理论都是处理不确定性信息的有效工具，而粗糙不确定性信息和模糊不确定性信息在很多情况下是并存的，如何将两者有效结合，并和神经网络集成，构造出具有综合信息处理能力的粗模糊神经网络或模糊粗神经网络值得深入研究。

参考文献

[1] Pawlak Z. Rough set theory and its application to data analysis. *Cybernetics and Systems*, 1998, 29(9): 661-688.
 [2] Pawlak Z. Rough set theory for intelligent industrial applications. *Intelligent Processing and Manufacturing of*

Materials, IPMM'99, Honolulu, 10-15 July, 1999, 1: 37-44.
 [3] 张东波, 王耀南, 易灵芝. 粗集神经网络及其在智能信息处理领域的应用. *控制与决策*, 2005, 20(2): 121-126.
 Zhang Dong-bo, Wang Yao-nan, and Yi Ling-zhi. Rough neural network and its application to intelligent information processing. *Control and Decision*, 2005, 20(2): 121-126.
 [4] Banerjee M, Mitra S, and Pal S K. Rough fuzzy MLP: Knowledge encoding and classification. *IEEE Trans. on Neural Networks*, 1998, 9(6): 1203-1216.
 [5] Yu Chunyan, Wu Minghui, and Wu Ming. Combining rough set theory with neural network theory for pattern recognition. *International Conference on Robotics, Intelligent Systems and Signal Processing*, Changsha, 2003: 880-885.
 [6] Chen Shuangye and Yi Jikai. A fuzzy neural network based on rough sets and its applications to chemical production process. *Info-tech and Info-net*, 2001. Proceedings, Beijing Oct 29-Nov 1, 2001, 4: 405-410.
 [7] Wu Zhaocong. Research on remote sensing image classification using neural network based on rough sets. *Info-tech and Info-net*, 2001. Proceedings, Beijing Oct 29-Nov 1, 2001, 4: 279-284.
 [8] Pawlak Z. Rough Logic, *Bulletin of the Polish Academy of Sciences, Technical Science*, 1987, 35: 253-258.
 [9] 张文修, 吴伟志, 梁吉业等. 粗糙集理论与方法, 北京: 科学出版社, 2001: 98-115.
 [10] 王耀南. 计算智能信息处理技术及其应用. 长沙: 湖南大学出版社, 1999: 147-176.
 [11] 姚洪兴, 赵林度, 盛昭瀚. 多级模糊神经网络在故障诊断中的应用. *东南大学学报*, 2001, 31(2): 59-63.
 Yao Hong-xing, Zhao Lin-du, and Sheng Zhao-han. Application of multi-grade fuzzy neural networks in fault diagnosis of large machinery. *Journal of Southeast University(Natural Science Edition)*, 2001, 31(2): 59-63.
 [12] Dougherty J, Kohavi R, and Shami M. Supervised and unsupervised discretization of continuous features. *Proceedings of 12th International Conference on Machine Learning*, Morgan Kaufmann, 1995: 194-202.
 [13] Nguyen H S and Skowron A. Quantization of real-valued attributes. *Second International Joint Conference on Information Sciences*, Wrightsville Beach, NC, 1995: 34-37.
 [14] Dubois D and Prade H. Rough-fuzzy sets and fuzzy-rough sets. *International Journal of General Systems*, 1990, 17(2-3): 191-209.
 [15] Sarkar M and Yegnanarayana B. Fuzzy-rough membership functions. 1998 IEEE International Conference on Systems, Man and Cybernetics, San Diego, CA, USA, Oct. 11-14, 1998, 2: 2028-2033.
 [16] Sarkar M and Yegnanarayana B. Rough-fuzzy membership functions. *The 1998 IEEE International Conference on Fuzzy Systems Proceedings*, Anchorage, AK USA, May 4-9, 1998, 1: 796-801.

张东波: 男, 1973年生, 讲师, 博士生, 从事粗糙集、神经网络、图像处理和模式识别等的研究。

王耀南: 男, 1957年生, 教授, 博士生导师, 从事人工智能、智能控制、图像处理和模式识别等的研究。