

文章编号: 1001-0920(2006)02-0221-04

## 一种新型模糊-粗神经网络及其在元音识别中的应用

张东波<sup>1,2</sup>, 王耀南<sup>1</sup>

(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, 湖南 湘潭 411105)

**摘 要:** 为度量模糊粗不确定性信息, 引入了模糊粗隶属函数. 基于模糊粗糙集理论构建了一种新型的模糊-粗神经网络(FRNN), 该网络融合了模糊信息和粗糙信息的处理能力. 对 5 个元音字母的语音识别进行测试, 结果显示 FRNN 网络不仅训练速度快, 而且分类性能优于 BP 网络、RBF 网络和贝叶斯分类器.

**关键词:** 模糊粗糙集; 模糊粗隶属函数; 模糊-粗神经网络; 元音识别

中图分类号: TP18

文献标识码: A

## Fuzzy-rough Neural Network and Its Application to Vowel Recognition

ZHANG Dong-bo<sup>1,2</sup>, WANG Yao-nan<sup>1</sup>

(1. College of Electrical and Information Engineering, Hu'nan University, Changsha 410082, China; 2 Institute of Information Engineering, Xiangtan University, Xiangtan 411105, China. Correspondent: ZHANG Dong-bo, E-mail: zhadonbo@sina.com)

**Abstract:** To measure the fuzzy-rough uncertainty, a fuzzy-rough membership function is introduced. A FRNN (Fuzzy-rough Neural Network) is designed based on fuzzy-rough set theory. The FRNN integrates the ability to process fuzzy and rough information. The test result of speech recognition for five vowel characters indicates that the FRNN has the merit of quick learning and it has better classification performance than BP network, RBF network and Bayesian classifier.

**Key words:** Fuzzy-rough set; Fuzzy-rough membership function; Fuzzy-rough neural network; Vowel recognition

### 1 引 言

模糊集理论<sup>[1]</sup>可用于处理人类思维过程中广泛存在的没有明确界限的模糊概念和模糊信息. 在模糊集合理论中, 论域中的元素和模糊集合的关系不能用绝对属于或绝对不属于来描述, 而只能用介于 0-1 之间的隶属度来表示, 具有模糊不确定性. 粗糙集是处理分类知识中存在的不确定性的一种数学理论<sup>[2]</sup>, 其中基于不可分辨关系对论域的划分所形成的等价类是构建知识库的基本模块(概念). 模糊集和粗糙集提供了对不确定环境的描述和建模, 但二者具有明显的区别: 模糊集所处理的是内涵明确而

界限不清晰(相互交叠)的集合; 粗糙集处理的是在现有知识下内涵不明确(粗糙)而界限清晰的集合. 它们分别是对不确定性环境中两种不同的不确定性的描述.

在分类问题中, 不可分辨关系将输入模式空间分为若干等价类, 通过这些等价类来描述给定的输出类. 当缺少必要的特征属性而不能进行精确描述时, 便会产生粗糙性, 表现在输入特征空间内存在难以区分的混合样本区. 在现实情况中, 两个输入模式不可能完全相同, 而是具有一定的相似性, 这时不可分辨关系划分采用的是一种相似关系划分, 相应的

收稿日期: 2004-12-31; 修回日期: 2005-04-22

基金项目: 国家自然科学基金项目(60375001); 高等学校博士点基金项目(20030532004); 湖南省教育厅科研基金项目(05C093).

作者简介: 张东波(1973—), 男, 湖南邵阳人, 讲师, 博士生, 从事粗糙集、神经网络等研究; 王耀南(1957—), 男, 昆明人, 教授, 博士生导师, 从事人工智能、智能控制等研究.

等价类变成了模糊聚类

模糊性和粗糙性的并存, 导致人们对模糊集和粗糙集理论集成的研究, Dubois 等<sup>[3]</sup>, Sarkar 等<sup>[4,5]</sup>, Nanda<sup>[6]</sup>, 吴伟志等<sup>[7,8]</sup>对此作了深入研究. 若不可分辨关系为等价关系, 而输出类是模糊集, 则可用粗糙模糊集来分析. 若不可分辨关系为模糊相似关系, 输出类也是模糊集, 则可用模糊粗糙集来分析. 粗糙模糊集和模糊粗糙集比单纯的模糊集和粗糙集对复杂环境具有更强的信息处理能力, 已在图像处理<sup>[4]</sup>、网上搜索智能体<sup>[9]</sup>、模式识别<sup>[4,10]</sup>、近邻分类<sup>[11]</sup>、股市分析<sup>[12]</sup>等领域得到有效的应用

### 2 基本理论

#### 2.1 粗糙集<sup>[2]</sup>

假设论域  $U$  是非空集合,  $R$  是  $U$  上的等价关系, 则根据  $R$  可将  $U$  划分为一些基本的互不相交的等价类集合  $U/R$ , 其中包含元素  $x$  的等价类用  $[x]_R$  表示. 任意的集合  $A \subseteq U$ , 都可用  $R$  上下近似集  $\bar{R}(A), R(A)$  表示为

$$R(A) = \{ [x]_R \mid [x]_R \subseteq A, x \in U \}, \quad (1a)$$

$$\bar{R}(A) = \{ [x]_R \mid [x]_R \cap A \neq \emptyset, x \in U \}. \quad (1b)$$

$BN_R(A) = \bar{R}(A) - R(A)$  称为集合  $A$  的  $R$  边界域; 若  $R(A) = \bar{R}(A)$ , 即  $BN_R(A) = \emptyset$ , 则集合  $A$  是粗糙集. 粗糙集可用粗隶属函数定义为

$$r_A(x) = \frac{|[x]_R \cap A|}{|[x]_R|}. \quad (2)$$

其中  $|A|$  表示求集合的势值. 如果  $A$  为普通集合, 则  $r_A(x)$  为  $A$  所包含的元素个数. 粗隶属函数  $r_A(x)$  可衡量根据  $R$  和  $x$  可能被划分到  $A$  的确定性程度.

#### 2.2 粗糙模糊集<sup>[3,4]</sup>

假设集合  $A$  是论域  $U$  上的模糊集,  $R$  是等价关系, 则二元体  $\bar{R}(A), R(A)$  可变成粗糙模糊集, 上下近似集  $\bar{R}(A)$  和  $R(A)$  也成为  $U/R$  上的模糊集. 相应的隶属函数定义为

$$\mu_{R(A)}([x]_R) = \inf\{\mu_A(x) \mid x \in [x]_R\}, \quad (3a)$$

$$\mu_{\bar{R}(A)}([x]_R) = \sup\{\mu_A(x) \mid x \in [x]_R\}. \quad (3b)$$

输入模式  $x$  关于输出模糊集  $C_c$  的粗模糊隶属函数定义为

$$t_c(x) = \frac{|[x]_R \cap C_c|}{|[x]_R|}. \quad (4)$$

如果  $C_c$  是界限清晰的普通集合, 则粗模糊隶属函数可简化为粗隶属函数.

#### 2.3 模糊粗糙集<sup>[3,5]</sup>

如果对论域  $U$  进行划分的关系  $R$  是模糊关系, 则  $U/R$  对  $U$  的划分是一种模糊弱划分, 形成模糊聚

类  $\{F_1, F_2, \dots, F_H\}$ ,  $F_j (j = 1, 2, \dots, H)$  为正规模糊集, 每个  $F_j$  都对应一个模糊语义变量. 输出类集  $C_c (c = 1, 2, \dots, C)$  的上下近似集也是模糊集, 其隶属函数定义为

$$\mu_{\bar{C}_c}(F_j) = \inf_x \{ \max(1 - \mu_{F_j}(x), \mu_{C_c}(x)) \}, \forall x; \quad (5a)$$

$$\mu_{C_c}(F_j) = \sup_x \{ \min(\mu_{F_j}(x), \mu_{C_c}(x)) \}, \forall x. \quad (5b)$$

二元体  $\bar{C}_c, C_c$  称为模糊粗糙集, 模式  $x$  关于  $C_c$  的模糊粗不确定性可通过模糊粗隶属函数表示为

$$T_c(x) = \begin{cases} \frac{1}{H} \sum_{j=1}^H \mu_{F_j}(x) t_c(x), & \exists j, \mu_{F_j}(x) > 0; \\ 0, & \text{否则} \end{cases} \quad (6)$$

其中  $t_c(x) = \frac{|[x]_R \cap C_c|}{|[x]_R|}$  为相应的粗模糊隶属函数,  $H$  是  $\mu_{F_j}(x) > 0$  的聚类数目.

模糊粗隶属函数融合了模糊性和粗糙性的不确定性度量, 是模糊隶属函数和粗隶属函数的推广.

### 3 基于模糊粗隶属函数的神经网络

在模式分类问题中, 模糊性和粗糙性的不确定性信息往往是并存的, 而模糊粗糙集理论中的模糊粗隶属函数是对模糊粗不确定信息的一种综合度量, 能较好的实现这两种不确定性信息的融合处理. 本文基于模糊粗隶属函数构建了一种模糊-粗神经网络(FRNN), 如图 1 所示.




图 1 模糊-粗神经网络结构

#### 3.1 网络结构

网络共为 4 层: 1) 输入层, 神经元数取决于输入模式的特征数; 2) 模糊聚类层, 神经元数取决于输入特征空间的聚类数, 模糊聚类可采用监督式或非监督式的模糊聚类算法来实现; 3) 模糊粗隶属层, 神经元数由输出类别数确定; 4) 输出层, 神经元数由输出类别数确定.

假设以  $net_i^j$  和  $O_j^i$  表示第  $i$  层第  $j$  个神经元的输入和输出, 则各层输入输出映射关系如下:

第 1 层

$$net_j^1 = x_j, O_j^1 = net_j^1, j = 1, 2, \dots, m. \quad (7)$$

其中:  $x_j$  是输入模式  $x = (x_1, x_2, \dots, x_m)^T$  的第  $j$  个特征,  $m$  为输入空间维数.

第 2 层

$$\text{net}_j^2 = x = (x_1, x_2, \dots, x_m)^T, j = 1, 2, \dots, H; \quad (8)$$

$$O_j^2 = \exp\left[-\frac{(\text{net}_j^2 - m_j)^T(\text{net}_j^2 - m_j)}{2\sigma_j^2}\right] = \exp\left[-\frac{(x - m_j)^T(x - m_j)}{2\sigma_j^2}\right]. \quad (9)$$

其中:  $m_j$  和  $\sigma_j$  分别为聚类中心和方差,  $O_j^2$  为模式  $x$  属于聚类  $j$  的隶属度, 即  $O_j^2 = \mu_{F_j}(x)$ ,  $H$  为聚类数.

第 3 层

$$\text{net}_j^3 = \sum_{i=1}^H O_i^2 w_{ij}^{23}, j = 1, 2, \dots, n. \quad (10)$$

其中:  $w_{ij}^{23}$  是第 2 层第  $i$  个神经元到第 3 层第  $j$  个神经元间的权值,  $n$  为输出类别数. 本层输出激励函数  $f^3$  为正切 S 型函数  $\text{tansig}$ , 有

$$O_j^3 = f^3(\text{net}_j^3) = \frac{2}{[1 + \exp(-2\text{net}_j^3)]} - 1, \quad j = 1, 2, \dots, n. \quad (11)$$

第 4 层

$$\text{net}_j^4 = \sum_{i=1}^n O_i^3 w_{ij}^{34}, j = 1, 2, \dots, n. \quad (12)$$

其中:  $w_{ij}^{34}$  是第 3 层第  $i$  个神经元到第 4 层第  $j$  个神经元间的权值,  $n$  为输出类别数. 本层输出激励函数  $f^4$  为对数 S 型函数  $\text{logsig}$ , 有

$$O_j^4 = f^4(\text{net}_j^4) = \frac{1}{1 + \exp(-\text{net}_j^4)} = C_j, \quad j = 1, 2, \dots, n. \quad (13)$$

$O_j^4$  表示各输出类别

### 3.2 网络参数确定和训练算法

网络涉及到的参数有各层的权值  $w_{ij}^{12}, w_{ij}^{23}, w_{ij}^{34}$  以及聚类中心  $m_j$  和方差  $\sigma_j$ . 其中  $m_j$  和  $\sigma_j$  由聚类算法确定, 不需训练.  $w_{ij}^{12}$  为第 1 层到第 2 层神经元连接权值, 取定值 1, 只负责输入模式的信号传递.  $w_{ij}^{23}$  为第 2 层到第 3 层神经元连接权值, 可通过所有的训练样本集来估算. 令

$$w_{ij}^{23} = \frac{1}{H} t_{c_j}^i(x) = \frac{1}{H} \frac{F_i - C_j}{F_i} = \frac{1}{H} \sum_{x \in C_j} \mu_{F_i}(x) / \sum_{x \in C_j} \mu_{F_i}(x). \quad (14)$$

这里采用高斯聚类模型, 任何模式  $x$  都满足  $\mu_{F_i}(x) > 0$ , 所以  $\hat{H} = H$ . 于是

$$\text{net}_j^3 = \sum_{i=1}^H O_i^2 w_{ij}^{23} = \frac{1}{H} \sum_{i=1}^H \mu_{F_i}(x) t_{c_j}^i(x) \quad (15)$$

即为模糊粗隶属函数  $\tau_{c_j}(x)$ . 网络需训练的参数只有  $w_{ij}^{34}$ , 可以通过 BP 算法来求取. 取误差指标函数

$$J = \frac{1}{2} \sum_j [d_j - C_j]^2, j = 1, 2, \dots, n. \quad (16)$$

其中:  $d_j$  表示期望输出,  $C_j$  是实际输出,  $n$  为输出类别数. 则有

$$\frac{\partial J}{\partial w_{ij}^{34}} = \frac{\partial J}{\partial C_j} \frac{\partial C_j}{\partial \text{net}_j^4} \frac{\partial \text{net}_j^4}{\partial w_{ij}^{34}} = (d_j - C_j) \frac{\exp(-\text{net}_j^4)}{[1 + \exp(-\text{net}_j^4)]^2} O_i^3. \quad (17)$$

令

$$\delta_j^4 = (d_j - C_j) \frac{\exp(-\text{net}_j^4)}{[1 + \exp(-\text{net}_j^4)]^2}, \quad (18)$$

则有  $\partial J / \partial w_{ij}^{34} = \delta_j^4 O_i^3$ . 沿梯度下降方向,  $w_{ij}^{34}$  的调整算法为

$$w_{ij}^{34}(k+1) = w_{ij}^{34}(k) - \eta \frac{\partial J}{\partial w_{ij}^{34}} = w_{ij}^{34}(k) - \eta \delta_j^4 O_i^3. \quad (19)$$

其中:  $w_{ij}^{34}(k+1)$  和  $w_{ij}^{34}(k)$  分别为第  $k+1$  次和第  $k$  次迭代时的权值,  $\eta$  为学习速率.

### 4 用于元音识别的性能测试

本文通过对元音字母 a, e, i, o, u 的语音识别, 测试所构建的神经网络 FRNN 的性能. 为避免数据来源过于单一, 从 3 个不同人的讲话中提取出这些元音字母的语音数据, 通过线性预测分析, 提取 3 个最主要的频率成分  $F_1, F_2, F_3$  作为样本的特征属性.

图 2 绘出了 5 类样本在  $F_1-F_2$  平面的分布情况. 从获得的有限样本分布情况看, 各类样本的正态分布性能并不很好, 而且各类样本之间存在难以区分的混合样本区. 从粗糙集的观点看, 这是缺乏更多的有效特征描述所造成的. 在当前 3 个特征描述的特征空间内, 显然同时存在模糊性和粗糙性.




图 2 元音字母在  $F_1-F_2$  平面的分布

上述元音字母的分类是一个 5 类样本的分类问题, 输入特征为  $F_1, F_2, F_3$  3 个主频率成分, 所以 FRNN 网络输入层取 3 个神经元. 采用监督式模糊聚类技术, 以各类的训练样本估算各类的中心和方

差,将样本划分为5个聚类,因此模糊聚类层取5个神经元.模糊粗隶属层和输出层的神经元数由输出类别数决定,均为5个神经元,所以网络结构为3:5:5:5.全部初始样本为632个,对样本进行归一化处理,每类随机选取60个样本总共300个样本作为训练样本,其余332个样本作为测试样本

各类期望输出分别为: $C_1 = (0.9, 0.1, 0.1, 0.1, 0.1)$ ,  $C_2 = (0.1, 0.9, 0.1, 0.1, 0.1)$ , ...,  $C_5 = (0.1, 0.1, 0.1, 0.1, 0.9)$ .实际输出类按最大原则进行判别.训练开始时,对进行训练的权值 $w_{ij}^{34}$ 先初始化为接近于0的随机数值,网络在15步之内即可收敛.为进行比较,在去掉模糊粗隶属层后,得到相应的RBF网络结构模型3:5:5.本文还采用传统的贝叶斯分类器和BP网络,对同样的语音样本进行分类器设计和性能测试,分类结果如表1所示

表1 测试样本分类结果 %

元音字母	贝叶斯分类器	BP网络	RBF网络	FRNN网络
a	86.21	75.86	72.41	75.86
e	50	66.67	66.67	66.67
i	96.43	100	98.21	99.11
o	89.77	81.82	90.91	92.05
u	90.11	86.81	90.11	89.01
全部样本	90.36	88.25	90.66	91.27

从样本的分布情况看,i类样本与其余各类分离得最好,最易划分;e类样本与i,a,o类样本都存在混合交叠区域,最难区分.这可从测试结果上体现出来,各种分类器对i类的分类精度最高,而e类分类精度最低.这也表明e,i,a,o 4类样本的划分具有较大的粗糙不确定性

RBF网络结构是在去掉模糊粗隶属层后获得的,因此它实际上只具有模糊信息处理能力,对a,i,o类样本的分类精度分别为72.41%,98.21%,90.91%.融合了模糊粗不确定性信息处理能力的FRNN网络,在保留原有模糊相似信息的基础上,在很大程度上减少了分类中的粗糙不确定性,使3类样本的分类精度分别提高到75.86%,99.11%,92.05%.从理论上说,贝叶斯分类器有最小分类错误率,但这必须建立在样本完全符合正态分布,并且具有足够多的训练样本的假设条件下,在不满足假设条件的情况下,贝叶斯分类器不一定能获得最好的分类性能.从表1可以看出,FRNN的平均分类精度比其他分类方法高,分类性能也有明显的提高

## 5 结 语

为更好地处理分类问题中的模糊粗不确定性,本文基于模糊粗糙集理论中的模糊粗隶属函数,构建了一种新型的模糊-粗神经网络(FRNN),并将其

用于元音字母的语音识别.测试结果表明,本文所设计的FRNN不仅训练速度快,而且分类性能优于BP网络、RBF网络和贝叶斯分类器,是一种融合了模糊信息和粗糙信息处理能力的多智能神经网络.它尤其适用于具有较大粗糙不确定性的混合样本区的划分

## 参考文献(References)

- [1] Zadeh L A. Fuzzy Sets[J]. *Information and Control*, 1965, 8(3): 338-353
- [2] Pawlak Z. Rough Set Theory and Its Application to Data Analysis[J]. *Cybernetics and Systems*, 1998, 29(9): 661-688
- [3] Dubois D, Prade H. Rough Fuzzy Sets and Fuzzy Rough Sets[J]. *Int J of General Systems*, 1990, 17(2-3): 191-208
- [4] Sarkar M, Yegnanarayana B. Rough-fuzzy Membership Functions [A]. *The 1998 IEEE World Congress on Computational Intelligence* [C]. Alaska, 1998, 1: 796-801.
- [5] Sarkar M, Yegnanarayana B. Fuzzy-rough Membership Functions [A]. *1998 IEEE Int Conf on Systems, Man and Cybernetics* [C]. California, 1998, 2: 2028-2033
- [6] Nanda S. Fuzzy Rough Sets [J]. *Fuzzy Sets and Systems*, 1992, 45(2): 157-160
- [7] 吴伟志, 张文修, 徐宗本. 粗糙模糊集的构造与公理化方法[J]. *计算机学报*, 2004, 27(2): 197-203  
(Wu W Z, Zhang W X, Xu Z B. Characterizing Rough Fuzzy Sets in Constructive and Axiomatic Approaches[J]. *Chinese J of Computers*, 2004, 27(2): 197-203)
- [8] 张诚一, 卢昌荆. 关于模糊粗糙集的相似度量[J]. *计算机工程与应用*, 2004, 40(9): 58-59, 68  
(Zhang C Y, Lu C J. On Measures of Similarity between Fuzzy Rough Sets [J]. *Computer Engineering and Application*, 2004, 40(9): 58-59, 68)
- [9] Ponthap Rojanavasu, Quin Pinngern. Extended Rough Fuzzy Sets for Web Search Agent [A]. *25th Int Conf Information Technology Interfaces* [C]. Cavtat, 2003: 402-407.
- [10] Sarkar M, Yegnanarayana B. Rough-fuzzy Set Theoretic Approach to Evaluate the Importance of Input Features in Classification [A]. *1997 Int Conf on Neural Networks* [C]. Texas, 1997, 3: 1590-1595
- [11] Sarkar M. Fuzzy-rough Nearest Neighbors Algorithm [A]. *2000 IEEE Int Conf on Systems, Man and Cybernetics* [C]. Nashville, 2000, 5: 3556-3561.
- [12] Wang Y F. Mining Stock Price Using Fuzzy Rough Set System [J]. *Expert System with Applications*, 2003, 24(1): 13-23