

一种基于超盒表示的规则提取方法

陈 曦,靳东明,李志坚

(清华大学微电子学研究所,北京 100084)

摘 要: 提出一种从训练样本提取基于超盒表示的模糊规则的方法,用于模式分类.这种方法把模式空间划分成模糊超盒,作为模糊规则的前件,规则的后件是相应的类别名称,同时给出每一条模糊规则的置信度.模糊分类规则从训练样本通过学习算法提取.规则提取方法可以分为,对于单个训练模式进行规则前件和后件的局部在线学习,和对于全部训练模式进行循环学习.实验显示规则提取的过程,说明通过这种方法能够获得有效的模式分类规则.

关键词: 模式分类;模糊规则;规则提取;超盒

中图分类号: TN01 **文献标识码:** A **文章编号:** 0372-2112(2002)09-1379-05

A Method for Rule Extraction Based on Hyper-Box Representation

CHEN Xi, JIN Dong-ming, LI Zhi-jian

(Institute of Microelectronics Tsinghua University, Beijing 100084, China)

Abstract: In this paper, we discuss a new method for rule extraction based on hyper-box representation. The method is deduced from the MRCC model, used for pattern classification. The method partitions the pattern space with multi-dimensional fuzzy hyper-boxes, and assigns a class label with certainty degree for each variable fuzzy region. These rules are extracted from numerical data through a recursive learning procedure. Experiment shows the efficiency of rule extraction procedure.

Key words: pattern classification; fuzzy rule-based classifier; rule generation; hyper-box

1 引言

模糊逻辑系统(FLS)通常采用 IF-THEN 形式的规则表示知识,它的工作过程容易理解.因此,如何获得模糊规则是一个重要的问题.

通常,智能系统获取知识有两种途径:一种是专家知识,例如专家系统和传统的模糊逻辑系统;另一种是训练样本,即模式-类别对,例如机器学习系统和神经网络.通过不同途径获取的知识通常采用不同的表示方法.如果同时使用则需要额外的转换过程,例如混合系统.为了从训练样本提取模糊规则,需要一种表示知识的统一方法.

超盒是指空间中各边都和坐标轴平行多维矩形,如图1.一个超盒直接对应一条 IF-THEN 形式的模糊规则:

IF $x_1 \in \{v_1, w_1\}$ and $x_2 \in \{v_2, w_2\}$ THEN x belongs to class 1. 从而用统一的形式表示两种知识,得到了广泛应用^{[1][2][3]}.

本文基于多分辨率组合分类器(MRCC)模型^[4]提出一种的采用超盒表示的模糊规则提取方法,用于模式分类问题.规则的前件是表示模式空间一个区域的超盒,规则的后件是确

定的类别标记和表示规则置信度的参数.当表示不同类别的规则前件超盒相互重叠时,重叠部分的类别标记由置信度最大的规则决定.

下面,第二部分介绍几种基于超盒表示的规则提取模型,第三部分介绍基于模糊规则的模式分类器结构和推理方法,第四部分介绍模糊规则提取算法,第五部分通过实验说明模糊规则提取过程,第六部分是结论.

2 基于超盒表示的规则提取模型

超盒表示的知识直接对应 IF-THEN 形式的模糊规则,可以直接从专家知识获取,容易理解和使用.并且,表示一个超盒通常只需要确定模式空间中每一个维度的最小点和最大点.从而可能通过简洁快速的学习算法从训练样本获取知识.这里介绍几种基于超盒表示的规则提取模型,NGE^[1], Fuzzy ARTMAP^[2], FMMC^[3], ARC^[5], FNNC^[6], ALFC^[7]和 MRCC^[4].这些模型方法都能够从训练样本通过监督学习提取知识,采用超盒划分模式空间,建立用于模式分类的决策边界.

在这些模型中,NGE, Fuzzy ARTMAP, FMMC, ARC 采用在线学习方法.在线学习是指一个训练样本只依次出现一次.学习算法根据训练样本修正已有的知识或者添加新建的知识.具体的讲,这些系统在初始化时在模式空间中没有任何超盒,或者每个超盒都退化为一个点.每当一个新的训练样本出现,就根据这个样本调整已有的超盒或者添加新建的超盒.采用




图1 超盒表示的一条模糊规则

收稿日期:2002-03-20;修回日期:2002-06-21

基金项目:高等学校博士学科点专项科研基金资助课题(No.98000338)

在线学习方法的模型有一个共同的缺点,即训练结果严重依赖训练样本出现次序.因此,在线学习系统通常需要采用其它方法加以改进,例如 Fuzzy ARIMAP 采用表决(voting).FNMC,ALFC 采用离线学习方法,或者称为批量学习方法.批量学习是指训练样本不是一个一个的依次出现,而是作为整体出现.学习算法根据全部训练样本初始化知识集合,然后根据特定部分样本修正知识集合.具体的讲,这些系统在初始化时根据全部训练样本建立若干超盒.然后根据特定部分样本,对于超盒重叠区域进行进一步的操作,或者建立一组新的超盒,或者将重叠区域重新划分,直到模式空间中的每一个区域都有明确的类别标记.采用批量学习方法克服了在线学习方法的缺点,训练结果不再依赖训练样本出现次序.但是批量学习方法的每一步学习都需要操作大量训练样本,增加了学习过程的复杂度和训练时间.

为了保持在线学习方法简洁的特点,一次处理一个训练样本,同时克服训练结果严重依赖训练样本出现次序的缺点.MRCC 模型通过循环训练建立多分辨率组合的超盒模型,在超盒模型中引入置信度参数,并且通过局部均匀分布(LUD)假设在线修正置信度参数.MRCC 模型一次学习一个训练样本.在一批训练样本学习结束以后,可以用这些训练样本重新训练,也可以用分布规律相同的其它训练样本再次训练.我们称 MRCC 模型采用的这种学习方法为在线学习方法.采用 MRCC 模型建立的模式分类器不仅具有良好的分类性能,而且学习过程建立的超盒数较少.采用 MRCC 模型,学习算法只需要给定和期望的分类器性能相关的参数,具有较高的自适应能力.以上优点说明 MRCC 模型适合作为规则提取的模型方法.以下介绍采用 MRCC 模型的基于模糊规则的模式分类系统,和相应的规则提取算法.

3 基于模糊规则的模式分类器

3.1 模式分类和模糊规则

模式分类问题就是对于一个模式,记为 x ,从预先给定的类别集合 $C = \{C_1, \dots, C_M\}$ 中选出一个类别 C_j 赋予这个模式,其中模式用 N 维单位空间 $x \in I^N$ 中的一个点表示.于是分类器的设计就是要确定一个映射:

$$D: I^N \rightarrow C \quad (1)$$

优化某个衡量分类器性能的评价函数 $F(D)$.目的是使得分类器对于全部模式空间的模式分类获得最小的错误概率.

基于 MRCC 模型的模式分类器模型采用模糊超盒作为划分模式空间的多维模糊集合,模糊规则的后件包含相应的类别名称和置信度.这样的模糊规则可以表示成以下形式:

$$R_j: \text{IF } x_1 \text{ is } A_1^j \text{ and } \dots \text{ and } x_N \text{ is } A_N^j \text{ THEN } y \text{ is } C_k \text{ with } CF_j$$

其中 $A_i^j = \{v_i^j, w_i^j\}$ 表示第 i 维模糊子空间对应的模糊集合, CF_j 表示规则 R_j 的置信度.用公式(2)表示:

$$CF_j = s_k^j / s^j, \quad (2)$$

其中 s_i^j 表示前件模糊子空间中和这个规则所对应的类别 C_k 相同的模式隶属于这个模糊前件集合的隶属度的和, s^j 表示前件模糊子空间中全部模式隶属于这个模糊前件集合的隶属

度的和.

3.2 模糊规则的推理方法

超盒由它在模式空间中的最小点和最大点描述,依次表示为矢量 V_j 和 W_j ,用隶属度函数 DOF_{B_j} 确定空间任意一点 X_h 隶属于这个超盒的隶属度值.通过比较 X_h 隶属于不同类别超盒的隶属度值对 X_h 进行分类.每一个超盒模糊集合 HB_j 定义为一个有序集合

$$DOF_j(X_h) = \{X_h, V_j, W_j, CF_j, b_j(X_h, V_j, W_j, CF_j)\} \quad (3)$$

对于全部 $h = 1, 2, \dots, H$,其中 X_h 是第 h 个输入模式, $V_j = (V_{j1}, V_{j2}, \dots, V_{jn})$ 是第 j 个超盒 HB_j 的最小点, $W_j = (W_{j1}, W_{j2}, \dots, W_{jn})$ 是第 j 个超盒 B_j 的最大点,第 j 个超盒 HB_j 的隶属度函数是 $DOF_j(X_h, V_j, W_j, CF_j)$,满足 $0 \leq DOF_j \leq 1$. CF_j 表示这条模糊规则的置信度.带有置信度参数的模糊超盒隶属度函数定义为:

$$DOF_j(X_h) = \min_{i=1, \dots, n} (\min([1 - f(x_{hi} - w_{ji}, r_i)], [1 - f(v_{ji} - x_{hi}, r_i)])) \times CF_j \quad (4)$$

其中, $f(z, r)$ 是两个参数的斜坡阈值函数

$$f(z, r) = \begin{cases} 1, & \text{if } zr > 1 \\ zr, & \text{if } 0 \leq zr \leq 1 \\ 0, & \text{if } zr < 0 \end{cases} \quad (5)$$

其中 x_{hi}, v_{ji}, w_{ji} 是矢量 X_h, V_j, W_j 的第 i 个单元, r 是灵敏度参数,调整隶属度函数随 X_h 和 HB_j 的距离增加而减小的速度.简单的讲,这个隶属度函数计算输入模式在各个维度上的隶属度值的最小值.第 k 类模式 C_k 的模糊集合定义为:

$$C_k = \bigcup_{j \in k} HB_j \quad (6)$$

4 模糊规则提取算法

首先介绍模糊规则提取算法中的几个重要组成部分,然后介绍规则提取算法的步骤.采用 MRCC 模型的规则提取采用在线学习方法,分为两个层次,一个层次是针对一个训练样本的局部在线学习,另一个层次是针对多个训练样本的循环学习.

4.1 局部在线学习

对于一个训练样本,局部在线学习分别调整每一条模糊规则的前件和后件.其中,规则前件调整模糊超盒的最小点和最大点,规则后件调整规则的置信度.

4.1.1 规则前件的在线学习

规则前件的在线学习主要是指,在已经建立的模糊规则中根据输入的训练样本,搜索并且选择一条规则,通过调整规则前件的模糊超盒,学习这个训练输入携带的信息.规则前件的在线学习包含两个步骤:选择一条规则进行调整和调整这条规则前件的模糊超盒.

算法选择满足以下条件的规则进行调整:规则后件所标明的类别与输入训练模式所属的类别相同;并且输入模式对于该规则的超盒隶属度值最大;该规则的前件模糊超盒满足如下尺度限制

$$\bigvee_{i=1, \dots, n} (\max(W_{ji} - X_{hi}) - \min(V_{ji} - X_{hi})) \leq \theta \quad (7)$$

其中 $\theta \in [0, 1]$,是超盒最大尺度限制.满足以上约束使得模

糊超盒在调整以后仍然满足每一个维度的尺度都小于 θ 。

如果在已经建立的规则中没有满足以上条件的规则,那么就建立一条新的规则描述这个训练输入,描述规则的主要参数为:

$$V_j = X_h, W_j = X_h, p_j = 1 \tag{8}$$

如果规则 R_j 满足以上条件,那么就如下调整它的前件模糊超盒,称为超盒扩张:

$$\begin{aligned} V_j^{new} &= \min(V_j^{old}, X_{hi}) \text{ for } \forall i = 1, \dots, n \\ W_j^{new} &= \max(W_j^{old}, X_{hl}) \text{ for } \forall i = 1, \dots, n \end{aligned} \tag{9}$$

4.1.2 规则后件的在线学习

规则后件的在线学习主要是指根据训练样本调整规则置信度.为此需要确定模式在模式空间中局部的分布规律.对于这里采用模糊超盒作为模式在模式空间的聚类模型,我们假设各类模式在一个模糊超盒中呈现均匀分布.引入模式空间密度 ρ 描述均匀分布.特别的,定义 ρ^* 为与模糊超盒所代表的类别相同的模式在该模糊超盒中的密度,定义 $\rho^\#$ 为各类模式在该超盒中密度的和.于是 $\rho^\# - \rho^*$ 为与模糊超盒所代表的类别不同的模式在该模糊超盒中密度的和.如果 N^* 表示与模糊超盒所代表的类别相同的模式在该模糊超盒中的数目, $N^\#$ 表示各类模式在该超盒中数目的和, V 表示模糊超盒的体积.那么, ρ^* 和 $\rho^\#$ 表示可以表示为:

$$\rho^* = \frac{N^*}{V}, \rho^\# = \frac{N^\#}{V} \tag{10}$$

另外,根据置信度 CF_j 的定义,它可以用 ρ^* 和 $\rho^\#$ 表示:

$$p_j = \frac{y_k^j}{s_j^j} = \frac{\rho^*}{\rho^\#} \tag{11}$$

对于一个训练输入,根据训练样本 $\{X_h, D_h\}$ 和规则 R_j 前件模糊超盒 HB_j 的关系,存在以下几种情况:模式 X_h 不包含在超盒 HB_j 内部,模式 X_h 包含在超盒 HB_j 内部,以及超盒 HB_j 经过超盒扩张包含模式 X_h .另外,考虑模式 X_h 和超盒 HB_j 的类别,下面分情况具体各种可能的情况和处理方法.

A. 模式 X_h 不包含在超盒 HB_j 内部,那么不需要调整置信度 CF_j .

B. 模式 X_h 包含在超盒 HB_j 内部,那么置信度 CF_j 需要根据这个输入模式进行调整.根据模式 X_h 的类别与超盒 HB_j 表示的类别,有以下两种情况:

a. 如果模式 X_h 的类别与超盒 HB_j 表示的类别相同,那么超盒内部模式空间密度如下变化

$$\rho^{* new} = \frac{N^{* old} + 1}{V^{old}} = \rho^{* old} + \frac{1}{V^{old}} \tag{12}$$

$$\rho^{\# new} = \frac{N^{\# old} + 1}{V^{old}} = \rho^{\# old} + \frac{1}{V^{old}} \tag{13}$$

b. 如果模式 X_h 的类别与超盒 B_j 表示的类别不相同,那么超盒内部模式空间密度如下变化

$$\rho^{* new} = \frac{N^{* old}}{V^{old}} = \rho^{* old} \tag{15}$$

$$\rho^{\# new} = \frac{N^{\# old} + 1}{V^{old}} = \rho^{\# old} + \frac{1}{V^{old}} \tag{16}$$

C. 超盒 HB_j 经过超盒扩张包含模式 X_h ,那么置信度 CF_j 需要

根据这个输入模式进行调整.因为超盒扩张是学习算法中唯一改变超盒形状的操作,所以在一般状态下,超盒扩张所增大的区域中除了这个输入的模式以外,不包含其它相同类别的模式.另一方面,对于与超盒表示的类别不同的模式,按照局部均匀分布假设^[4],这些模式的空间密度在扩张前后的超盒中保持不变.因此,可以得到扩张以后那么超盒内部模式空间密度,

$$\text{令 } V^{new} = V^{old} \times A \tag{18}$$

$$\text{则 } \rho^{* new} = \frac{N^{* old} + 1}{V^{new}} = \frac{1}{A} \left(\rho^{* old} + \frac{1}{V^{old}} \right) \tag{19}$$

$$\begin{aligned} \rho^{\# new} &= \rho^{* new} + (\rho^{\# new} - \rho^{* new}) \\ &= \frac{1}{A} \left(\rho^{\# old} + \frac{1}{V^{old}} \right) + (\rho^{\# old} - \rho^{* new}) \end{aligned} \tag{20}$$

在学习过程中,有两种情况使局部均匀分布假设偏离实际情况:一种情况是,当一个超盒内部的训练模式数目较少时,不足以体现模式分布的实际情况,即违反了模式分布均匀的假设;另一种情况是,当一个超盒扩张系数 A 较大时,扩张以后的超盒远大于扩张以前的超盒,即违反了在局部考察模式分布的假设.为了克服学习过程中的实际情况可能和假设偏离较大的情况,我们增加一个约束同时处理上面的两种情况.设定超盒扩张系数的最大值为 A_{max} ,当 $A > A_{max}$ 时,令 $A = A_{max}$.

4.2 循环学习

根据学习理论的基本原理,在对于训练集合的分类性能相同的条件下,结构复杂度最低的的分类器的推广能力最好.根据这一原理,学习优化的目标函数包含两项,分别衡量分类器分类的错误率和分类器的复杂度^[5],最优的模式分类器能够使评价函数 $F(D)$ 达到最小.

$$F = (1 - \lambda)E + \lambda C \tag{22}$$

其中 E 是分类器对于训练模式分类的错误率, C 是建立的规则数与训练集中模式-类别对的数目之比,表征结构复杂度, $\lambda \in [0, 1]$ 是根据经验确定的权重,用以平衡对分类器的学习性能和推广能力的考虑.如果设置 λ 的值比较小,那么建立的网络结构就会比较复杂,对于训练模式的分类错误率也比较低,反之,如果设置 λ 的值比较大,那么建立的网络结构就会相对简单,对于训练模式的分类错误率也相对比较高.在一般情况下,可以选取一个折中的值,例如 $\lambda = 0.5$.

对于采用模糊超盒作为模糊规则前件的分类器,允许建立超盒的最大尺度 θ 是对学习结果影响很大的参数.如果 θ 的值太大,会使分类器的错误分类率较高,尤其对于复杂,相互重叠的类别;如果 θ 的值太小,会使学习过程建立的规则数目过多.而且,虽然较小的 θ 取值有助于划分重叠的类别,但是建立规则数目过多会导致分类器的推广能力下降.

MRC模型采用一种称为多分辨率超盒组合的方法,而不是用固定尺度限制的模糊超盒.具体做法是,在学习过程开始的时候,选择一个比较大的超盒尺度限制 θ_{max} .由于允许建立尺度较大的超盒,所以只需要较少数目的模糊规则就能够覆盖全部训练模式.但是,由于尺度较大的超盒对模式空间的划分过于粗略,分类器的性能不会很好.这时,我们分别考察

所建立的模糊规则,保留那些置信度达到某一要求的规则.例如,设定规则的置信度最小值为 CF_{min} ,如果规则 R_j 的置信度 $p_j \geq p_{min}$,则保留这条规则,否则就从已经建立的规则中删除这条规则.然后,减小对超盒尺度的限制,例如,令 $\theta = \theta_{min} - \delta\theta$.使用与前一次学习相同的训练样本集合,或者使用一组分布规律相同新的训练模式集合,在前一次学习过程保留下来的模糊规则的基础上重复前一次的学习过程.依此类推,直到评价函数 $F(D)$ 达到预先确定的目标 F_{min} ,或者达到规定的最小值 θ_{min} .

因此,循环学习的每一步骤实际包含了若干训练样本依次在线学习和对已经建立模糊规则验证两个阶段.通过在线学习从训练样本提取模糊规则,超盒尺度限制 θ 是影响学习结果的关键参数,因此算法通过逐渐减小 θ 的取值提高模式空间局部细节的建模能力.算法只需要给定 θ 的初始值 θ_{max} 和最小值 θ_{min} ,它们都不单独对规则提取过程起到重要影响.这个特性提高了规则提取过程的自适应能力.超盒扩张系数的最大值为 A_{max} 在学习过程中起到一定限制作用,防止据均匀分布假设偏差较大造成的错误推断,尤其对于学习过程初期和模式空间训练样本较少的情况.在规则验证阶段,通过控制规则置信度的最小值 CF_{min} ,保留置信度高的规则,删除置信度低的规则,保证规则提取结果的性能.另外,评价函数目标 F_{min} 和均衡提取规则数目和分类性能的参数 λ 的值也会对规则提取过程产生影响.尽管基于 MRCC 模型的规则提取算法具有较高的自适应能力,恰当的设置以上参数仍然能够在分类性能,规则数目和训练时间等因素之间获得优化考虑.

4.3 模糊规则提取算法

在局部在线学习和循环学习算法的基础上,介绍模糊规则提取算法,包括以下步骤:




图2 当 $\theta = \theta_{max} = 0.8$ 时, 规则提取建立的超盒




图3 规则提取建立的超盒和分类边界

在初始化时 θ_{max} 设置为一个较大的值,尝试用最少的规则覆盖全部训练样本,如图2所示.这时,三条规则就覆盖了全部训练样本.但是,前件超盒较大的两条规则不仅覆盖了本类样本,还覆盖了较多其它类别的样本,所以规则置信度较低,在后续学习过程中被删除,如图3所示.在图3中可以看到,右上方尺度较大的超盒被保留下来,成为最终得到的模糊规则之一.大尺度的超盒在规则提取早期取得并保留,一方面减少了最终提取的规则数,一方面能够加快后续循环训练的速度,因为包含在已经确定的超盒中的训练样本不再用于新的训练.循环训练重复上述过程,不断有较小的超盒被保留,成为

第1步,确定训练参数 $\theta_{max}, \theta_{min}, \delta\theta, A_{max}, CF_{min}, F_{max}$ 和评价函数的权重 λ ,确定一组用于训练的模式-类别对.

第2步,输入训练模式-类别对,检测它和已经建立的模糊规则之间的关系,相应的进行扩张模糊规则前件超盒或者建立一条新的模糊规则.

第3步,调整已经建立的超盒的置信度参数 CF .如果还有未参加训练的模式-类别对,则返回第2步,否则继续执行.

第4步,计算评价函数的值 F .

第5步,如果评价函数的值 F 满足预先定义的要求 F_{min} ,则跳转执行第9步,否则继续执行.

第6步,减小超盒尺度限制参数 θ 的值.

第7步,如果超盒尺度限制参数 θ 达到预先确定的最小值 θ_{min} ,则跳转执行第9步,否则继续执行.

第8步,考察每一条建立的模糊规则,删除置信度 CF 低于要求的规则,保留其余的规则,重新确定一组用于训练的模式类别对,跳转执行第2步.

第9步,学习过程结束.

5 规则提取实例

这里通过一个例子说明上述规则提取算法.试验采用两类二维的训练样本,通过学习提取带有置信度参数 CF 的模糊分类规则.这些模糊规则组合在一起就构成模式分类器.

两类训练样本是相对的呈香蕉形状分布的样本,每一类包含50个样本.图3显示样本分布和通过规则提取得到的模式分类器的分类边界,以及规则提取得到的基于超盒表示的模糊规则.学习参数设置: $\theta_{max} = 0.8, \theta_{min} = 0.1, \delta\theta = 0.1, A_{max} = 2, CF_{min} = 0.9, F_{min} = 0, \lambda = 0.5$.




图4 超盒个数随超盒最大尺度限制减小的变化




图5 评价函数随超盒最大尺度限制减小的变化

确定的模糊规则.直到 $\theta_{min} = 0.1$,达到预先设定的最小值,就形成了如图3显示的12条模糊规则.

图4显示了学习过程中所建立的超盒个数随超盒最大尺度限制减小变化的情况.说明随超盒最大尺度限制减小,算法提取得到规则数增加,规则所表示的模式空间减小.规则所描述的事实更加具体、细致.图5显示了学习过程中评价函数的数值随超盒最大尺度限制减小变化的情况.说明在循环学习过程中,评价函数不像梯度下降算法单调减小,这种特性有利于模型得到全局优化结果,避免陷入局部优化结果.

6 结论

对于从训练输入输出对这样的数值数据中直接提取模糊规则用于模式分类的问题,提出一种新的规则提取方法.这种规则提取方法以 MRCC 模型为基础,把模式空间划分成模糊超盒.采用模糊超盒划分模式空间,一方面具有类似神经网络灵活的建模能力,一方面适合采用模糊逻辑 IF-THEN 形式推理规则表示,易于分析和修改.通过实验详细说明模糊规则提取的过程,表明这种方法能够用较少的分类规则有效地描述训练数据的分布规律.

参考文献:

- [1] S Salzberg. A nearest hyperrectangle learning method [J]. Machine Learning, 1991, (6):251 - 276.
- [2] G A Carpenter, et al. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps [J]. IEEE Trans on Neural Networks, 1992, 3(5):698 - 713.
- [3] P K Simpson . Fuzzy min-max neural networks-part 1: classification [J]. IEEE Trans on Neural Networks, 1992, 3(5):776 - 786.
- [4] 陈曦,靳东明,李志坚.一种多分辨率组合的模糊神经网络分类器 [J]. 电子学报, 2002, 30(5):830 - 835.
- [5] Rizzi, M Panella, F M Frattale Mascioli, G Martinelli. A recursive algorithm for fuzzy min-max networks [A]. Proc Inter J Conf Neural Networks [C]. IEEE Service Center, Piscataway, NJ USA:2000.

- [6] M Meneganti, et al. Fuzzy neural networks for classification and detection of anomalies [J]. IEEE Trans on Neural Networks, 1998, 9(5): 848 - 861.
- [7] S Abe, M. - S Lan, A method for fuzzy rules extraction directly from numerical data and its application to pattern classification [J]. IEEE Trans on Fuzzy Systems, 1995, 3(1):18 - 28.

作者简介:



陈 曦 男,1975 年 7 月出生于上海市,清华大学微电子所博士研究生.1998 年毕业于清华大学电子工程系,直读博士学位.主要研究方向是模糊逻辑、神经网络、学习算法和硬件实现.电子邮件:chenxi98@mail.tsinghua.edu.cn

靳东明 男,1942 年 2 月出生于天津市,清华大学微电子所教授、博导.1965 年毕业于清华大学无线电系,并留校任教.目前主要在多值逻辑、模糊控制和神经网络的硬件实现方面开展研究工作.

李志坚 男,1928 年 5 月生于浙江省,清华大学教授,中科院院士.研究领域包括 MEMS, SOC 和纳米电子器件.