

基于粗集理论的雷达辐射源信号识别

张葛祥^{1,2}, 金炜东¹, 胡来招²

(1. 西南交通大学电气工程学院, 610031, 成都; 2. 电子对抗国防科技重点实验室, 610036, 成都)

摘要: 将粗集理论(RST)引入到雷达辐射源信号(RES)识别中, 提出一种区间连续属性离散化新方法及相应的特征选择算法, 将 RST 与神经网络(NN)结合, 设计粗集神经网络(RNN)分类器. 实验结果表明, 该方法解决了已有方法难以处理的区间连续属性离散化问题, 获得的正确识别率比其他 3 种方法分别高出 7.29%、4.34% 和 4.00%. RNN 的平均训练代数比 NN 少 97.54, RNN 的平均识别率比 NN 高 2.84%, 这表明 RNN 具有比 NN 更好的分类能力和泛化能力, 从而证实了该方法的有效性和可行性.

关键词: 信号识别; 粗集理论; 雷达辐射源

中图分类号: TN957; TP18 **文献标识码:** A **文章编号:** 0253-987X(2005)08-0871-05

Radar Emitter Signal Recognition Based on Rough Set Theory

Zhang Gexiang^{1,2}, Jin Weidong¹, Hu Lai Zhao²

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. National EW Lab, Chengdu 610036, China)

Abstract: Rough set theory (RST) was introduced into radar emitter signal recognition. A novel approach was proposed to discretize interval-valued continuous attributes, and the corresponding feature selection method was presented. Rough set neural network (RNN) classifier was designed by combining RST and neural network (NN). Experimental results show that the proposed approach solves the problem of interval-valued continuous attribute discretization existing methods are unable to deal with, and achieves higher 7.29%, 4.34% and 4.00% recognition rate than that of the other methods. The average training generations of RNN are 97.54 less than that of NN and the average recognition rate of RNN is higher 2.84% than that of NN, which indicates that RNN has stronger capabilities of classification and generalization than NN to be expectantly applied to the practice.

Keywords: signal recognition; rough set theory; radar emitter

在现代电子战中, 通过搜索、截获、定位、分析和识别雷达辐射源信号(RES), 电子情报侦察系统(ELINT)、电子支援系统(ESM)和雷达告警系统(RWR)为预警、威胁探测、威胁避免和实时反击部署提供宝贵信息^[1]. RES 识别是 ELINT、ESM 和 RWR 的关键部分, 是衡量电子对抗设备技术水平的重要标志^[1,2]. 特征提取往往采用经验式或启发式方法, 且 RES 中存在大量噪声, 提取的特征常带有主观性和猜测性, 特征易分散和交叠, 需要引入特

征选择法来对多种特征进行筛选.

粗集理论(RST)是一种新的软计算基础理论, 无需任何先验知识和外部信息便能从大量数据中挖掘出决策规则, 揭示出属性间的关联关系并删除冗余属性, 且 RST 导出的决策规则易于理解^[3-5]. 由此, 本文首次将 RST 引入到 RES 识别中, 提出区间连续属性离散化和特征选择法, 设计粗集神经网络分类器, 实现 RES 的分类识别. 实验结果表明, 本文方法优于新特征选择法(NFS)^[6]和顺序前进法

(SFS)^[7]. RST的引入加快了神经网络(NN)的学习速度,增强了NN的泛化能力和容错能力,提高了识别效率和正确率.

1 区间连续属性离散化

RST只能处理离散属性值,连续属性离散化是RST在实际应用中首先要解决的问题.由于噪声等影响,RES特征不是固定值,而是在某一范围内变化的区间值.已有离散化方法^[3-5]采用断点划分法分割不同的点属性值,对于区间属性值,无法进行有效的处理.由此,将基于断点划分的点属性值离散化定义推广到基于类别可分离性的区间属性值离散化(IVAD)定义,描述如下.

决策表 $S = \langle U, R, V, f \rangle$, 其中 $R = C \cup \{d\}$ 是属性集合,子集 $C (C = \{c_1, c_2, \dots, c_m\})$ 和 $\{d\}$ 分别为条件属性集和决策属性集, $U = \{x_1, x_2, \dots, x_n\}$ 为论域.属性 $c_i (c_i \in C, i = 1, 2, \dots, m)$ 的值域为

$$V_{c_i} = \{[v_{c_i^1}^{\min}, v_{c_i^1}^{\max}], [v_{c_i^2}^{\min}, v_{c_i^2}^{\max}], \dots, [v_{c_i^n}^{\min}, v_{c_i^n}^{\max}]\} \quad (1)$$

式中: $v_{c_i^j}^{\min}, v_{c_i^j}^{\max} \in R (j = 1, 2, \dots, n)$. 采用类别可分离性准则函数 $J(V_{c_i})$ 对属性 $c_i (c_i \in C)$ 进行划分,得到论域 U 的一个等价关系 R_{c_i} , 即得到论域 U 的一个分类.于是,对于属性集 C ,可以得到由 m 个等价关系 $R_{c_1}, R_{c_2}, \dots, R_{c_m}$ 构成的等价关系族 $P (P = \{R_{c_1}, R_{c_2}, \dots, R_{c_m}\})$. 这样,等价关系族 P 就定义了一个新的决策表 $S^P = \langle U, R, V^P, f^P \rangle, f^P(x) = k, x \in U, k = \{0, 1, \dots\}$, 经过离散化后,原来的决策表就被一个新的决策表所代替.

上述定义的实质是将连续属性离散化过程视为函数映射关系,并称为类别可分离性准则函数,以强调类别的可分性.实现IVAD的关键是类别可分离性准则函数的选择.当属性值在某一区间取值时,一般而言,属性值总会呈现出一定的规律性,这种规律性可看成近似地遵循某种概率分布.设 $f(x)$ 和 $g(x)$ 均为一维连续非负实函数,分别表示决策表中属性 c_i 对应于论域 U 中任意两个对象的属性值概率分布函数,于是可引入如下的类别可分离性准则函数

$$J = 1 - \frac{\int f(x)g(x)dx}{(\int f^2(x)dx)^{1/2}(\int g^2(x)dx)^{1/2}} \quad (2)$$

式中: J 的值域为 $[0, 1]$.

函数 J 满足文献^[7]中的类别可分离性判据的

3个条件:非负;不交叠时达最大值;完全重叠时为最小值0.由于 $f(x)$ 和 $g(x)$ 均为非负实函数,故可由著名的Cauchy Schwartz不等式得到

$$0 \leq \int f(x)g(x)dx \leq (\int f^2(x)dx)^{1/2}(\int g^2(x)dx)^{1/2} \quad (3)$$

函数 J 可用来判断两类别是否可分的说明如下:若函数 $f(x)$ 和 $g(x)$ 分别表示论域 U 中两个对象 A 和 B 的属性值概率分布函数,若对所有使 $f(x) \neq 0$ 的点都有 $g(x) = 0$, 或者对所有使 $g(x) \neq 0$ 的点都有 $f(x) = 0$, 则 A, B 两类是完全可分的,函数 J 取得最大值1;若对某些使 $f(x) \neq 0$ 的点也有 $g(x) \neq 0$, 则 A, B 两类是部分可分的,函数 J 的值介于0和1之间,即 $0 < J < 1$;若对所有 x 都有 $f(x) = kg(x)$ ($k \in R^+$), 则 A, B 两类是完全不可分的,函数 J 取得最小值0.因此,采用式(2)给出的准则函数来判断两类的可分离程度是合理的.需要说明的是,式(2)中的函数 $f(x)$ 和 $g(x)$ 为满足条件的任意分布函数.

根据式(2)中给出的类别可分离性准则函数,区间属性值离散化算法描述如下:

- (1) 初始化,确定论域 U 中对象的数目 n 和属性集中的元素数目 m ;
- (2) 构造决策表,将所有属性值排列成二维决策表,表中的属性值均以区间值形式表示;
- (3) 选择类别可分离性阈值 T_h , 该阈值的大小将决定着设计者可以接受的两类分布函数重叠部分的大小,一般取值接近于1;
- (4) 将属性 c_i (开始时 $i = 1$) 中的所有属性值按中心点值进行从小到大的排序,排序后结果为 v_1, v_2, \dots, v_n ;
- (5) 将属性 c_i 中的最小属性值 v_1 处的编码 Code 设为0,作为离散化过程的初始值;
- (6) 从属性 c_i 中的最小属性值 v_1 开始,按排序后的顺序依次计算 v_k 和 v_{k+1} ($k = 1, 2, \dots, n-1$) 的可分离性准则函数值 J_k , 如果 $J_k \geq T_h$, 表示该两类对象是完全可分的,则使属性值 v_{k+1} 的对应位置编码 Code 加1, 否则 $J_k < T_h$, 表示该两类对象不完全可分,属性值 v_{k+1} 的对应位置的编码 Code 保持不变;
- (7) 重复执行(6),直到属性 c_i 中的所有属性值均被离散化为止;
- (8) 如果 $i \leq m$, 表明还有属性没有离散化,则 $i = i + 1$, 算法转到(4)重复执行,直到 $i > m$ 为止,表

明决策表中所有属性值均被离散化了;

(9) 用离散化后的决策表代替原先的决策表,以用于属性化简。

采用 IVAD 方法对属性表进行离散化处理时,各属性划分的维数不是事先指定,而是由算法自动确定,离散过程中也无需任何先验知识。

2 粗集神经网络分类器

NN 具有较强的模式识别能力,能够在高维模式空间中形成复杂的判决曲面,且具有较好的容错能力和泛化能力,但 NN 不能对输入信息进行优选和简化,当输入向量维数较高时,网络结构复杂,训练时间较长。RST 具有较强的定性分析能力和决策能力,能够对 NN 的输入数据进行预处理,提取其中的关键成分作为网络的输入,从而可以简化 NN 的结构,缩短训练时间,提高泛化能力。

将 RST 引入到 NN 中,设计出如图 1 所示的粗集神经网络(RNN)分类器。在图 1 中,先将训练样本集构成属性表,表中的各属性值均用区间值表示,采用 IVAD 对表中所有属性进行离散化,得到离散化后的属性表。然后,采用基于分辨矩阵和逻辑运算的属性约简法^[8]对离散属性表进行处理。属性约简后会同时得到所有可能的简化属性集,这往往造成简化后的属性子集有多个,故引入特征提取复杂性来对多个简化结果进行再一次挑选,以使最后产生的决策规则具有最小的代价。根据最后获得的简化属性集,利用 Naive Scaler 算法^[8]对 IVAD 离散后的属性表进行再一次离散化处理,确定各属性所需的断点数和断点位置,并依据 IVAD 离散前的属性表计算出相应断点位置处的断点值,从而确定出离散化规则,即 NN 输入数据的预处理规则。在对分类器进行测试或将该分类器用于实际应用时,将输入数据先经预处理规则处理后,再作为 NN 的输入。NN 采用 3 层 BP 网络结构,输入层神经元数目与选择出的最佳特征子集的特征数相同,分别作为预处理后的各特征值输入,中间层神经元数目取为 15,传递函数选择“tansig”函数,输出层神经元数目与待分类识别的 RES 数目相同,传递函数选择“logsig”函数。NN 训练算法采用弹性反向传播算法,监督信号取为“0-1”型信号,输出容差为 0.05,训练误差取为 0.001。

由于 NN 处理连续数据往往比处理离散数据需要更多的空间和时间,所以将 NN 的输入数据采用离散化方法处理后可节省存贮空间和处理时间,而

且还可加快 NN 的学习速度。

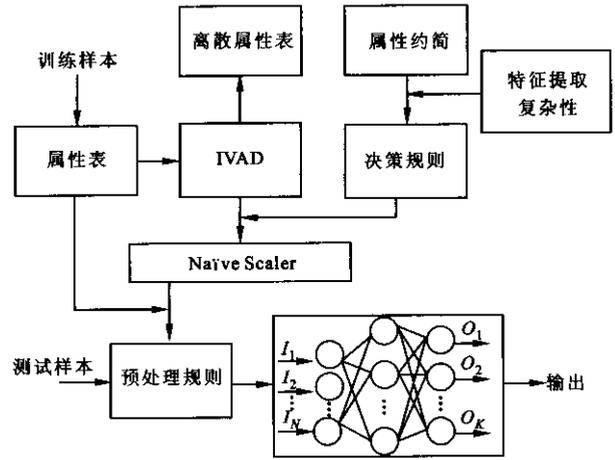


图 1 粗集神经网络分类器结构

3 实验结果分析

选取 CW、FD、LFM、NLFM、BPSK、QPSK、MPSK、IPFE、FSK 和 CSF 10 种典型的 RES 进行仿真实验,这些信号构成了论域 U , 分别用 x_1, x_2, \dots, x_{10} 表示。在前期工作中,作者已分别对这些 RES 的 16 种特征进行了研究^[2,9,10],这些特征构成了属性集,分别用 a_1, a_2, \dots, a_{16} 表示。

实验中,先在 5~20 dB 的信噪比(只考虑脉内噪声)范围内进行特征提取,得到如表 1 所示的属性表,表中所有属性值均为区间值,对于每一个属性值,表中给出的是其最小值和最大值。实验中采用的噪声为高斯白噪声,采用 IVAD 对表 1 进行离散化,得到如表 2 所示的新属性表。在离散化过程中,参数 $n=10, m=16, T_h=0.99$,各属性值均视为以数学期望和方差为参数的高斯分布函数。采用基于分辨矩阵和逻辑运算的属性约简法^[8]对表 2 进行约简,结果为

$$L = a'_{10} (a'_3 + a'_5 + a'_6) (a'_{12} + a'_{13} + a'_{14} + a'_{16}) \quad (4)$$

式中共有 12 种简化属性集,引入特征提取时间复杂性进行再一次挑选,得到具有最低复杂性的约简结果为 $a'_5 a'_{10} a'_{12}$ 。

为了测试约简结果的分类型性能,采用 NN 分类器(NNC)对 10 种 RES 进行识别。先对每一种 RES 在 5~20 dB 的信噪比范围内每隔 5 dB 产生 150 个样本,这样每一种 RES 总共有 600 个样本,其中 200 个样本用于 NNC 训练,其余 400 个样本用于分类识别的测试实验。由于属性约简的结果为 $a'_5 a'_{10} a'_{12}$,

故 NNC 的结构选取为 3-15-10. 在分类识别实验中, 先采用由 16 种特征组成的原始特征集(OFS)进行测试实验, NNC 结构为 16-25-10, 50 次实验的平均结果如表 3 所示. 然后, 采用属性约简后的 3 种特征进行实验, 在没有采用 RST 对 NN 输入数据进行处理时, 50 次实验所得的平均结果如表 3 第 5 行所示. 为了进行对比, 本文还采用 SFS^[7]和 NFS^[6]进行特征选择, SFS 获得的结果为 $a'_4 a'_5$, NFS 获得的结果为 $a'_6 a'_7$. 经 SFS 和 NFS 选出的特征的识别率也在表 3 中给出. 为了比较 NN 与 RNN 的分类识

别能力、训练时间和泛化能力, 再分别采用 10 个、20 个、30 个和 40 个训练样本来分别训练 NN 和 RNN, 然后分别用 5 dB、10 dB、15 dB 和 20 dB 的测试样本测试训练后的 NN 和 RNN, 测试实验进行了 50 次, 得到 NN 和 RNN 最终的平均识别率随样本数变化的曲线(如图 2 所示)和平均训练代数随样本数变化的曲线(如图 3 所示).

表 3 显示, 本文的特征选择法大大降低了原特征集的维数和特征提取的代价, 简化了分类器结构, 获得了比原特征集、NFS 和 SFS 分别高出 4.00%、

表 1 离散处理前的属性表

信号	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8
x_1	[0.690,0.707]	[1.402,1.404]	[0.122,0.125]	[0.270,0.272]	[0.434,0.437]	[1.961,2.301]	[0.951,1.021]	[0.420,0.433]
x_2	[0.671,0.682]	[1.429,1.576]	[0.115,0.162]	[0.213,0.277]	[0.361,0.428]	[1.088,2.991]	[1.115,1.261]	[0.405,0.455]
x_3	[0.546,0.598]	[1.582,1.586]	[0.292,0.3040]	[0.225,0.226]	[0.374,0.376]	[0.726,1.111]	[0.690,0.755]	[0.534,0.550]
x_4	[0.893,0.896]	[1.437,1.490]	[0.373,0.652]	[0.989,1.00]	[0.856,0.867]	[11.73,20.22]	[2.157,2.960]	[0.198,0.201]
x_5	[0.897,0.909]	[1.561,1.768]	[0.200,0.223]	[0.725,0.727]	[0.330,0.337]	[6.817,7.748]	[2.899,3.130]	[0.198,0.202]
x_6	[0.419,0.453]	[1.219,1.224]	[0.561,0.586]	[0.141,0.142]	[0.243,0.244]	[2.618,2.967]	[0.194,0.309]	[0.772,0.787]
x_7	[0.396,0.413]	[1.280,1.284]	[0.080,0.082]	[0.039,0.040]	[0.000,0.001]	[6.404,6.726]	[0.256,0.326]	[0.675,0.687]
x_8	[0.657,0.684]	[1.478,1.483]	[0.065,0.067]	[0.182,0.191]	[0.114,0.129]	[2.147,3.314]	[1.423,1.664]	[0.393,0.413]
x_9	[0.521,0.562]	[1.393,1.401]	[0.078,0.081]	[0.706,0.729]	[0.584,0.612]	[17.35,19.07]	[0.921,0.977]	[0.504,0.524]
x_{10}	[0.905,0.908]	[1.384,1.459]	[0.331,0.348]	[0.625,0.630]	[0.556,0.561]	[0.344,4.67]	[3.114,3.737]	[0.202,0.211]

信号	a_9	a_{10}	a_{11}	a_{12}	a_{13}	a_{14}	a_{15}	a_{16}
x_1	[41.02,41.15]	[25.50,25.87]	[15.41,15.73]	[23.00,23.37]	[2.459,2.542]	[3.681,3.775]	[11.72,11.97]	[22.51,22.88]
x_2	[41.18,50.26]	[29.27,36.34]	[10.39,15.44]	[23.63,31.04]	[0.947,5.257]	[3.139,5.668]	[7.477,9.556]	[21.54,26.255]
x_3	[109.0,110.8]	[80.45,82.10]	[28.45,28.84]	[66.86,68.40]	[13.54,13.74]	[2.009,2.292]	[7.037,7.240]	[5.718,5.867]
x_4	[1.569,1.591]	[1.567,1.575]	[0.000,0.024]	[1.555,1.577]	[0.000,0.013]	[0.000,0.012]	[0.000,0.013]	[1.546,1.576]
x_5	[1.583,1.613]	[1.585,1.591]	[0.000,0.024]	[1.573,1.589]	[0.000,0.015]	[0.000,0.012]	[0.000,0.013]	[1.561,1.584]
x_6	[462.4,478.1]	[361.1,373.9]	[101.4,103.9]	[235.5,244.8]	[125.5,129.2]	[51.88,52.90]	[49.62,51.09]	[85.05,89.04]
x_7	[273.4,275.1]	[204.0,205.6]	[69.31,69.88]	[127.3,128.5]	[76.20,77.58]	[40.94,41.37]	[28.18,28.41]	[43.69,44.42]
x_8	[38.31,40.15]	[28.34,29.58]	[9.963,10.579]	[17.69,18.28]	[10.66,11.13]	[2.332,2.516]	[7.618,8.073]	[14.35,14.66]
x_9	[117.0,119.3]	[96.44,98.11]	[20.47,21.26]	[71.09,71.99]	[25.29,26.18]	[13.29,13.87]	[7.162,7.381]	[51.58,52.14]
x_{10}	[1.769,1.877]	[1.769,1.848]	[0.000,0.030]	[1.760,1.823]	[0.022,0.120]	[0.000,0.015]	[0.000,0.016]	[1.718,1.771]

表 2 离散处理后的属性表

信号	a'_1	a'_2	a'_3	a'_4	a'_5	a'_6	a'_7	a'_8	a'_9	a'_{10}	a'_{11}	a'_{12}	a'_{13}	a'_{14}	a'_{15}	a'_{16}
x_1	1	2	0	0	1	0	2	1	2	2	1	3	1	2	1	3
x_2	1	2	0	0	1	0	2	1	2	3	1	3	1	2	1	3
x_3	0	2	1	0	1	0	1	1	3	4	3	4	3	1	1	6
x_4	2	2	1	1	2	1	2	0	0	0	0	0	0	0	0	0
x_5	2	2	0	1	1	1	2	0	0	0	0	0	0	0	0	0
x_6	0	0	1	0	1	0	0	3	6	7	5	7	6	5	3	7
x_7	0	1	0	0	0	1	0	2	5	6	4	6	5	4	2	4
x_8	1	2	0	0	1	0	2	1	2	3	1	2	2	1	1	2
x_9	0	2	0	1	1	1	2	1	4	5	2	5	4	3	1	5
x_{10}	2	2	1	0	1	0	2	0	1	1	0	1	0	0	0	1

表 3 几种方法识别结果的比较

方法	识别率/%										
	BPSK	QPSK	MPSK	LFM	NLFM	CW	FD	FSK	IPFE	CSF	平均
OFS	100.00	75.25	98.95	100.00	100.00	100.00	99.97	100.00	100.00	85.92	95.17
SFS	89.59	58.99	78.23	96.03	100.00	100.00	100.00	100.00	97.12	98.88	91.88
NFS	91.93	98.08	85.47	100.00	83.53	100.00	100.00	100.00	94.08	95.18	94.83
NN	100.00	97.80	95.61	100.00	100.00	100.00	100.00	100.00	98.26	100.00	99.17
RNN	100.00	100.00	99.80	100.00	100.00	100.00	100.00	100.00	99.80	100.00	99.96

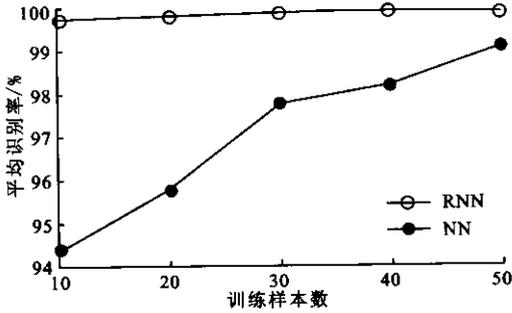


图 2 NN 和 RNN 的平均识别率随样本数变化的曲线

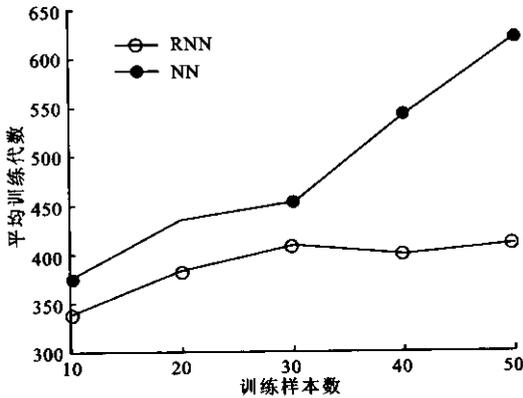


图 3 NN 和 RNN 的平均训练代数随样本数变化的曲线

4.34%和7.29%的正确识别率。RNN 获得的平均识别率比 NN 高 0.79%。图 2 和图 3 显示,在样本数变化的情况下,RNN 获得的平均识别率比 NN 高 2.84%,RNN 的平均训练代数比 NN 少 97.54。图 2 还说明 RNN 在训练样本数较少时的泛化能力大大强于 NN,图 3 还说明在训练样本数较多时,RNN 的训练时间比 NN 减少得更明显。

4 结束语

本文将 RST 引入到 RES 识别中,提出一种区间属性值离散化方法对 RES 特征值进行离散化处理,采用属性约简法从 16 种特征中挑选出由 3 种特征构成的特征子集,并采用 IVAD 和 Naive Scaler 混合法对 NN 的输入数据进行预处理,从而设计出 RNN 分类器来实现 RES 的自动分类识别。实验结

果表明,采用 RST 方法对 RES 特征进行选择和对 NN 的输入数据进行预处理,可大大降低原始特征集的维数,减少特征提取的代价,简化分类器的结构,缩短分类器的学习时间和提高正确识别率。本文提出的方法也适用于其他形式的模式识别、机器学习等问题。

参考文献:

- [1] Granger E, Rubin M A, Grossberg S, et al. A what-and-where fusion neural network for recognition and tracking of multiple radar emitters [J]. *Neural Networks*, 2001, 14(3): 325-344.
- [2] 张葛祥, 胡来招, 金炜东. 雷达辐射源信号脉内特征分析[J]. *红外与毫米波学报*, 2004, 23(6): 477-480.
- [3] Dai J H, Li Y X. Study on discretization based on rough set theory[A]. *Proc of the First Int Conf on Machine Learning and Cybernetics* [C]. Piscataway: IEEE Press, 2002. 1 371-1 373.
- [4] Tay F E H, Shen L X. Fault diagnosis based on rough set theory[J]. *Engineering Applications of Artificial Intelligence*, 2003, 16(1): 39-43.
- [5] Roy A, Pal S K. Fuzzy discretization of feature space for a rough set classifier[J]. *Pattern Recognition Letter*, 2003, 24(6): 895-902.
- [6] 吕铁军, 王 河, 肖先赐. 新特征选择方法下的信号调制识别[J]. *电子与信息学报*, 2002, 24(5): 661-666.
- [7] 边肇祺, 张学工. 模式识别[M]. 第二版. 北京: 清华大学出版社, 2000.
- [8] 王国胤. *Rough 理论与知识获取*[M]. 西安: 西安交通大学出版社, 2001.
- [9] Zhang G X, Hu L Z, Jin W D. Complexity feature extraction of radar emitter signals [A]. *Proc of 3rd Asia-Pacific Conf on Environmental Electromagnetics* [C]. Piscataway: IEEE Press, 2003. 495-498.
- [10] Zhang G X, Rong H N, Jin W D, et al. Radar emitter signal recognition based on resemblance coefficient features[A]. *Lecture Notes in Computer Science*, 3066 [C]. Berlin: Springer-Verlay GmbH & Company KG, 2004. 665-670.

(编辑 杜秀杰)