

# 粗糙 $K$ -means 和 AdaBoost 结合的雷达辐射源快速识别算法

王文哲<sup>1</sup>, 吴 华<sup>1</sup>, 索中英<sup>1,2</sup>, 陈 游<sup>1</sup>, 程嗣怡<sup>1</sup>

(1.空军工程大学航空航天工程学院,西安,710038; 2.空军工程大学理学院,西安,710051)

**摘要** 针对数据集识别难度分布不均匀,提出了基于粗糙  $K$ -means 和 AdaBoost 的雷达辐射源快速识别算法。该算法由 2 个阶段构成:初级识别阶段提出一种改进粗糙  $K$ -means 算法,将数据特征空间分割为确定区域、粗糙区域和不确定区域,构建雷达辐射源快速识别算法模型,对数据集进行筛选和识别,同时提出了一种确定粗糙  $K$ -means 算法初始聚类中心和聚类数量以解决其固有缺陷的思路;在高级识别阶段,基于粗糙区域已知数据训练的多类 AdaBoost 分类器识别不确定区域未知数据,提升识别精度。仿真结果表明:该算法与 RBF-SVM 和 AdaBoost 相比,精度浮动在  $-0.1\%$  到  $+1.4\%$  之间,训练时间和测试时间分别最大缩短 0.857 s 和 0.005 s,在保持了较高识别精度和泛化能力的同时,明显降低了计算复杂度,缩短了耗时,提供了设计雷达辐射源快速识别算法的新思路。

**关键词** 雷达辐射源识别;粗糙  $K$ -means;AdaBoost;计算复杂度

**DOI** 10.3969/j.issn.1009-3516.2016.01.010

**中图分类号** V243.2;TN974 **文献标志码** A **文章编号** 1009-3516(2016)01-0051-05

## A Fast Radar Emitter Recognition Algorithm Based on Rough $K$ -means Combined with AdaBoost

WANG Wenzhe<sup>1</sup>, WU Hua<sup>1</sup>, SUO Zhongying<sup>1,2</sup>, CHEN You<sup>1</sup>, CHENG Siyi<sup>1</sup>

(1.Aeronautics and Astronautics Engineering College, Air Force Engineering University, Xi'an 710038,China;  
2. Science College, Air Force Engineering University, Xi'an 710051,China))

**Abstract:** Aimed at the fact that data samples in the same data set are difficult to recognize because of mal-distribution, this paper proposes a fast radar emitter recognition algorithm based on rough  $K$ -means combined with AdaBoost. The algorithm is composed of two stages. At the primary recognition stage, an improved rough  $k$ -means algorithm is proposed, and the data feature space is divided into the certain area, the rough area and the uncertain area to construct a fast radar emitter recognition algorithm model so as to filter and recognize the data set. And at the same time a heuristic approach is proposed to solve the inherent shortcomings of the original rough  $K$ -means by ascertaining its initial clustering number and centers. And at the advanced recognition stage, unknown samples dwelling in the uncertain area are recognized by the multi-class AdaBoost classifier trained by the unknown ones in the rough area, thus promoting the recognition accuracy of the algorithm. The simulation results show that compared to RBF-SVM and AdaBoost, the scope of an accuracy fluctuation is from  $-0.1\%$  to  $+1.4\%$ , the shrinkage of a training time is 0.857 s,

**收稿日期:**2015-07-02

**基金项目:**陕西省自然科学基金(2012JQ8019)

**作者简介:**王文哲(1991-),男,山东济南人,硕士生,主要从事航空电子对抗技术研究. E-mail:524940802@qq.com

**引用格式:**王文哲,吴华,索中英,等. 粗糙  $K$ -means 和 AdaBoost 结合的雷达辐射源快速识别算法[J]. 空军工程大学学报:自然科学版,2016,17(1):51-55. WANG Wenzhe, WU Hua, SUO Zhongying, et al. A Fast Radar Emitter Recognition Algorithm Based on Rough  $K$ -means Combined with AdaBoost[J]. Journal of Air Force Engineering University: Natural Science Edition, 2016, 17(1): 51-55.

and the shrinkage of a test time is 0.005 s at most, and apparently the computational complexity is lowered and the time consumed is shortened respectively by using this new algorithm under conditions of reserving comparatively high recognition accuracy and generalization capability. By so doing, this provides fast radar emitter recognition algorithms-designing with new train of thought.

**Key words:** radar emitter recognition; rough  $K$ -means; AdaBoost; computational complexity

近年来,随着相控阵等新体制雷达不断涌现,对雷达侦察系统可靠性与实时性要求不断提高,雷达辐射源识别面临着更多挑战<sup>[1]</sup>,传统识别方法正在逐渐失效<sup>[2]</sup>。许多新的雷达辐射源识别方法陆续问世,如脉内特征分析<sup>[3]</sup>,基于句法模型的分析<sup>[4]</sup>和人工智能分析<sup>[5-6]</sup>等等。其中,人工智能分析方法受到了诸多关注。在其众多实现方法之中,神经网络和支持向量机(SVM)在雷达辐射源识别中得到了广泛应用<sup>[7-8]</sup>。然而,神经网络的预测精度并不高,且其需要较大的训练集<sup>[9]</sup>,而这实际上可能难以获取。相比神经网络,SVM能够在较小训练集下取得更好的预测精度<sup>[9]</sup>。然而,SVM的计算复杂度随着训练数据增多将急剧上升。因此,兼具高精度和低计算复杂度的识别方法正成为一个研究热点。近年来,Boosting在人工智能中应用广泛且有效,引起了学界重视。其中最具代表性的AdaBoost方法,被认为是统计学习中目前为止性能最好的方法之一,许多学者称其为最好的立即可用(out-of-the-box)分类器<sup>[9-10]</sup>。问题在于,能否在保留高精度的同时,进一步提升其实时性,使其更加适应该领域应用特点。

### 1 快速级联识别算法模型

混合不同分类器是构建所需识别算法的有效手段。混合分类器模型从结构上分为级联和并行。级联混合分类器通常有着结构简单、易于实现的优点。其中,后级分类器只对前级分类器拒回的训练数据进行分类。所以在设计这种分类器时,关键在于如何选择互补分类器和决定将被拒回的数据。

为使AdaBoost算法集中计算资源识别困难数据,首先应注意到此事实:在特征空间中,困难数据主要位于各类交界处。因此只要通过前级分类器筛选出交界附近数据送入AdaBoost即可。而粗糙 $K$ -means算法对特征空间的分割以及相比AdaBoost较低的计算复杂度使其非常适合作为级联模型的前级。然而初始聚类中心和数量需人为给定等固有缺陷,限制了其应用范围,因此本文将对其改进。经典粗糙 $K$ -means算法将特征空间分为确定区域和粗糙区域。但在本文改进的粗糙 $K$ -means算法中,特征空间中将存在3种区域,即确定区域、粗糙区域和

不确定区域。以二维数据为例,特征空间见图1。

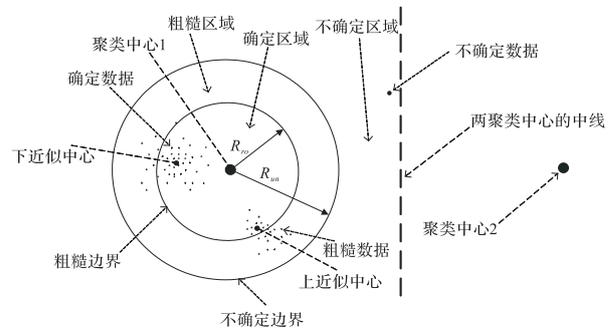


图1 本文改进粗糙 $K$ -means算法的区域划分  
Fig.1 Area division of the rough  $K$ -means algorithm improved by this paper

首先,改进粗糙 $K$ -means算法学习训练数据,可得聚类中心和各个区域的边界半径。其次,AdaBoost学习粗糙区域数据。至此,训练阶段完成,得到粗糙 $K$ -means分类器和AdaBoost分类器。

对未知类标记数据进行分类时,改进粗糙 $K$ -means分类器首先筛选数据,并识别确定区域和粗糙区域数据,继而AdaBoost分类器识别不确定区域数据。快速级联识别算法模型见图2。

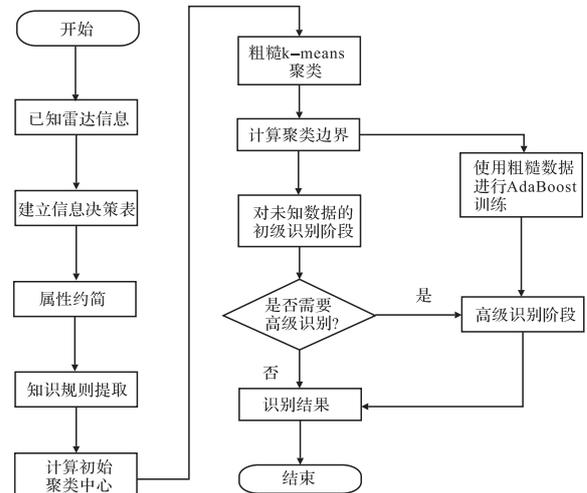


图2 本文算法流程

Fig.2 Flow chart of the algorithm proposed in this paper

基于以上模型,初级识别阶段拒回的数据在高级识别阶段识别,故本文算法识别精度应为:

$$A_t = A_p R_r + A_a R_d \tag{1}$$

式中:  $A_t, A_p, A_a, R_r, R_d$  分别为混合识别精度、初级识别高级识别阶段精度、初级识别阶段接受率和拒回率。

## 2 改进粗糙 $K$ -means 初级识别阶段

粗糙  $K$ -means 是最流行的迭代下降聚类算法之一<sup>[11]</sup>。 $K$ -means 算法的基本思想是尽量使得同类数据相似度高、异类数据相似度低。然而  $K$ -means 聚类算法有如下缺陷:①聚类数量必须在聚类前人为给出;②对初始聚类中心的选择非常敏感,且极易收敛于局部最优解;③对孤立点也很敏感。

为了解决孤立点问题,Pawan Lingras 和 Chad West 提出了粗糙  $K$ -means 算法<sup>[12]</sup>。粗糙  $K$ -means 算法可以解决聚类中的不确定性问题,并且有效减少孤立点的影响,但仍需初始聚类中心和聚类的数量作为先验知识。对此,本文基于粗糙集理论<sup>[13-14]</sup>来确定聚类数量和初始聚类中心。

### 2.1 基于粗糙集理论对粗糙 $K$ -means 算法的改进

由于粗糙集理论无法处理实值数据,信息表中数据应予离散化。数据离散化的方法很多,本文采用简单明确的等距离离散化法<sup>[14]</sup>。

在离散化后,使用粗糙集理论对数据进行属性约简和分类规则提取。基于这些分类规则,计算可得初始聚类中心。该过程如下:①基于粗糙集理论,获取分类规则;②设置聚类数量等于规则的数量;③定义初始聚类中心如下:

$$t_{i0} = \left( \sum_{x \in X_i} x \right) / \text{card}(X_i) \quad (2)$$

式中:  $X_i$  为分类规则  $i$  中的数据集。

在粗糙  $K$ -means 算法中,每次迭代更新的聚类中心为:

$$t_i = \begin{cases} \omega_{\text{lower}} \times \frac{\sum_{x \in \underline{X}_i} x}{\text{card}(\underline{X}_i)} + \omega_{\text{upper}} \times \frac{\sum_{x \in (\overline{X}_i - \underline{X}_i)} x}{\text{card}(\overline{X}_i - \underline{X}_i)}, & \text{if } \overline{X}_i - \underline{X}_i \neq \emptyset \\ \left( \sum_{x \in \underline{X}_i} x \right) / \text{card}(\underline{X}_i), & \text{otherwise} \end{cases} \quad (3)$$

式中:  $\overline{X}_i$  和  $\underline{X}_i$  分别为  $X_i$  的上近似集和下近似集,参数  $\omega_{\text{lower}}$  和  $\omega_{\text{upper}}$  分别为粗糙集上近似和下近似的相对重要性,或者称为权值,通常取值于  $0 \sim 1$  之间,二者之和为 1。

定义数据  $x_m$  和  $x_n$  的距离为:

$$d(x_m, x_n) = \|x_m - x_n\| \quad (4)$$

则数据  $x_m$  和类中心  $t_i$  的距离应为  $d(x_m, t_i)$ 。 $X_i$  的  $\omega_{\text{lower}}$  和  $\omega_{\text{upper}}$  权值基于  $d(x_m, t_i) / d_{\text{min}_i}$ , 其中  $d_{\text{min}_i} = \min_{i \in [1, I]} d(x_m, t_i)$ 。如果  $d(x_m, t_i) / d_{\text{min}_i} \geq \lambda$ , 则数据  $x_m$  应该归入  $X_i$  的下近似集,  $\lambda$  为判定上下近似集的门槛。否则,  $x_m$  应归入聚类中心距

离其最近的  $X_i$  上近似集但不归入  $X_i$  下近似集( $X_i$  下近似集是  $X_i$  上近似集的子集)。而权值由上近似集和下近似集中各自元素的数量决定:

$$\frac{\omega_{\text{lower}}(i)}{\omega_{\text{upper}}(i)} = \frac{\text{card}(\overline{X}_i - \underline{X}_i)}{\text{card}(\underline{X}_i)}, (\underline{X}_i \neq \emptyset) \quad (5)$$

$$\omega_{\text{lower}}(i) + \omega_{\text{upper}}(i) = 1 \quad (6)$$

因此,参数  $\lambda$  决定了式(2)中  $X_i$  的  $\omega_{\text{lower}}$  和  $\omega_{\text{upper}}$  权值。如果  $\lambda$  取值过大,那么下近似集将会是空集;相反如果  $\lambda$  取值过小,上下近似集的区分就会失去意义。

### 2.2 改进粗糙 $K$ -means 用于初级识别阶段

在训练粗糙  $K$ -means 分类器时,需计算类中心、粗糙边界和不确定边界,尔后使用该分类器时,仅需用到这些参数。

聚类完成后,确定了类中心和距离类中心最远的的数据。设  $d_x$  为数据  $x$  到类中心的距离。不确定边界半径定义为:

$$R_{\text{un}} = \max(d_x) \quad (7)$$

式中:  $\max(d_x)$  即为该类数据到类中心的最远距离。粗糙边界半径定义为:

$$R_{\text{ro}} = \delta R_{\text{un}} \quad (8)$$

一般地,比例系数  $\delta \in [0.7, 0.9]$ 。本文取 0.8。

图 1 中,粗糙边界和不确定边界之间的区域定义为粗糙区域,超出不确定边界半径的区域定义为不确定区域。根据以上定义,算法训练阶段不会有数据出现在不确定区域。

而当未知类标记数据被识别时,它们首先会被分入类中心距其最近的一类中。其中位于确定区域和粗糙区域的数据,由初级识别阶段给出最终分类结果,不确定区域数据则予以拒回。

## 3 基于 AdaBoost 的高级识别阶段

AdaBoost 由 Y. Freund 和 R. Schapire 在 1995 年提出<sup>[15-16]</sup>,很快成为目前最流行的提升(Boosting)方法。在提升方法中,其他学习算法的输出被“融合”成一个加权和的形式,该加权和代表了提升方法的最终输出。之所以称 AdaBoost 为自适应(Adaptive)的,意即在组成强分类器的弱分类器(weak learners)中,后续的弱分类器都要由之前已经生成的弱分类器所决定。

原始的 AdaBoost 算法是一种二类分类算法。为了使其能够用于多类分类问题,可以采用许多将二类分类算法推广到多类分类算法的通用策略,比如 One-Versus-The-Rest, One-Versus-One 等。基

于 AdaBoost 的多类分类算法也有许多学者发表了相关研究,比如 Y. Freund 和 R. Schapire<sup>[16]</sup>,以及 J. Zhu 等<sup>[17]</sup>的论文。本文采用应用最广的 One-Versus-The-Rest 策略对 AdaBoost 进行多类分类推广,即每次为一类数据建立一个 AdaBoost 分类器,对每一个分类器来说,只需将这一类别数据和其他所有类别数据区分开来。

训练时,AdaBoost 算法从初级识别阶段筛选出的粗糙区域数据中学习得到 AdaBoost 分类器;对未知类标记数据识别时,只有不确定区域数据被初级识别阶段拒回并送入 AdaBoost 分类器识别,而初级识别阶段接受的数据不经过此阶段识别。

### 4 实验仿真与分析

本文对所提出算法进行了仿真验证,Inter(R) Core (TM) i7-3770 @3.40 GHz CPU 和 4 GB 内存的微型计算机硬件平台,Python 2.7 及 Numpy 1.9.2 软件平台。识别精度和计算复杂度分别与 RBF-SVM 和 AdaBoost 基于以上平台进行了对比。

实验 1 对雷达辐射源信号所产生的数据进行识别;所涉及雷达辐射源信号脉冲描述字包含射频频率(RF)、脉冲重复频率(PRF)和脉冲宽度(PW);雷达辐射源类型为识别结果。

实验 2 使用 Iris 数据集,它包含了分属于 3 个类别的 150 个数据,每一类由 50 个数据构成,特征空间为四维实值空间。

#### 4.1 实验 1:雷达辐射源信号的分类

采用基于 9 个已知雷达辐射源信号产生的人工数据集。表 1 所示为已知雷达辐射源信息。

表 1 已知雷达信号数据信息表

Tab.1 The data information table of known radar signals

序号	RF/GHz	PRF/Hz	PW/ $\mu$ s	类型
1	8 346	1 600	0.15	3
2	8 590	1 300	0.25	3
3	7 850	1 500	0.5	1
4	7 806	750	0.1	1
5	7 909	585	0.5	2
6	7 967	580	0.5	2
7	7 920	620	0.5	2
8	7 857	750	0.5	1
9	7 786	1 500	0.1	1

训练和测试数据都是基于表 1 中数据集的随机生成数据,其中训练数据 270 个,测试数据 90 个。

经过等距离散化,属性值被归入 3 个区间。同区间实值被赋予同一离散值,见表 2。A, B, C 和 d 分别指代载频、重频、脉宽和雷达类型。

表 2 使用等距离散化法后的信息表

Tab.2 The discrete information table using the equivalent width method

序号	A	B	C	d
1	3	3	1	3
2	3	3	2	3
3	2	3	3	1
4	2	2	1	1
5	2	1	3	2
6	2	1	3	2
7	2	2	3	2
8	2	2	3	1
9	1	3	1	1

计算雷达类型对每一条件属性的依赖度: $\gamma_A = 1/2$ ,  $\gamma_B = 3/8$ ,  $\gamma_C = 0$ 。由于雷达类型对属性 C (PW)的依赖度为 0,故属性 C 为冗余。在属性约简和剔除重复数据后,可得表 3 的分类规则,其中 \* 表示任意值。

表 3 基于粗糙集理论提取的分类规则

Tab.3 The classification rules extracted based on rough sets theory

序号	A	B	d
1	3	3	3
2	2	3	1
3	1	3	1
4	2	2	1
5	1	2	2
6	*	1	2

表 3 中存在 6 条分类规则,即 3 种类型的 270 个数据可以被分入 6 个子类中,计算可得初始聚类中心并基于此训练 K-means 分类器。最终的 K-means 分类器参数见表 4。尔后使用粗糙区域数据训练 AdaBoost 分类器。

表 4 K-means 分类器的参数

Tab.4 Parameters of the K-means classifier

子类	聚类中心	粗糙半径	不确定半径
1	(8 467.9, 1 452.9)	175.0	218.8
2	(7 850.8, 1 497.6)	58.3	72.9
3	(7 786.0, 1 514.2)	70.7	88.4
4	(7 831.6, 751.7)	60.0	75.0
5	(7 919.3, 620.4)	4.9	6.2
6	(7 938.6, 582.8)	27.4	34.3

识别 90 个测试数据,可得精度参数。初、高级识别阶段精度,初级识别阶段接受率和拒回率分别为 95.6%, 97.3%, 89.7% 和 10.3%。由此,本文算法精度: $A_{total} = 95.6\% \times 89.7\% + 97.3\% \times 10.3\% = 95.8\%$ 。算法比较见表 5。

表 5 实验 1 的对比结果

Tab.5 Comparison results of experiment 1

分类算法	训练时间/s	测试时间/s	分类精度/%
RBF-SVM	2.634	0.012	94.4
AdaBoost	2.915	0.010	95.9
本文算法	2.058	0.007	95.8

从训练时间和测试时间上看,本文算法 2.058 s 和 0.007 s 都明显优于 RBF-SVM 和 AdaBoost 的实验结果,达到了大幅降低时间复杂度的目的;而从分类精度上来看,本文算法的 95.8% 仅略低于 AdaBoost 的 95.9%, 显然高于 RBF-SVM 的 94.4%。以上结果说明本文算法在取得低时间复杂度的同时,保持了较高的分类精度,有较好的泛化能力。

#### 4.2 实验 2: Iris 数据集的分类

从 UCI 机器学习数据库中选取了 Iris 数据集对算法进行测试。使用该数据集 90% 的数据训练分类器, 10% 的数据对分类器进行测试。具体训练和测试方法与实验 1 类似, 不同之处仅在于 Iris 数据集为真实采集的鸢尾花数据、无需生成随机数据, 因此不再赘述其过程。算法比较见表 6。

表 6 实验 2 的仿真结果

Tab.6 Comparison results of experiment 2

分类算法	训练时间/s	测试时间/s	分类精度/%
RBF-SVM	0.539	0.003	94.0
AdaBoost	0.644	0.001	93.7
本文算法	0.368	0.001	93.9

由表 6 可知, 本文算法在保持了相对较高的分类精度和泛化能力的同时, 运算时间仍然较 RBF-SVM 和 AdaBoost 有明显降低, 达到了预期目的。

需要指出的是, 在 2 次实验中, 本文算法的识别精度分别较 RBF-SVM 和 AdaBoost 低 0.1%。这是由于本文算法和 2 种对照算法均为泛化能力很强的高精度识别算法, 其测试性能会在一定程度上受到不同数据集的影响而略显差异。尽管本文算法在识别精度上不能明显区分于 2 种对照算法, 但其在缩短运算时间上的效果是显而易见的。

## 5 结论

本文提出了基于粗糙  $K$ -means 和 AdaBoost 的雷达辐射源快速识别算法。该算法由改进的粗糙  $K$ -means 分类器和 AdaBoost 分类器组成。基于数据集识别难度分布, 数据分别被前后 2 级分类器识别, 仿真实验取得了较理想的效果。此外:

1) 本文改进的粗糙  $K$ -means 算法给出了一种解决初始聚类中心和数量只能人为给定问题的方法, 对于粗糙  $K$ -means 算法随机性强、易陷入局部最优的问题提供了一种解决思路。

2) 提出了将改进的粗糙  $K$ -means 算法作为前级的快速级联分类器构建方法, 仿真实验表明, 对于一般数据集, 本文算法在保持了较高精度的同时, 明

显降低了算法的计算复杂度, 说明该方法可行, 对于雷达辐射源快速识别工程实现有借鉴意义。

#### 参考文献(References):

- [1] Guillaume Latombe, Eric Granger, Fred A Dilkes. Fast Learning of Grammar Production Probabilities in Radar Electronic Support[J]. Transactions on Aerospace and Electronic Systems, IEEE, 2010, 46(3):1037-1041.
- [2] P Bezousek, V Schejbal. Radar Technology in the Czech Republic[J]. Aerospace and Electronic Systems Magazine, IEEE, 2004, 19(8):27-34.
- [3] G X Zhang, L Z Hu, W D Jin. Intra-pulse Feature Analysis of Radar Emitter Signals[J]. Journal of Infrared Millimeter Waves, 2004, 23(6):477-480.
- [4] Guillaume Latombe, Eric Granger, Fred A. Dilkes. Graphical EM for on-line Learning of Grammatical Probabilities in Radar Electronic Support[J]. Applied Soft Computing, 2012, 12(8):2362-2378.
- [5] E Swierz. Automatic Classification of LFM Signals for Radar Emitter Recognition Using Wavelet Decomposition and LVQ classifier[J]. Acta Physica Polonica A, 2011, 119(4):488-494.
- [6] Z Yin, W Yang, Z Yang, et al. A Study on Radar Emitter Recognition Based on Spds Neural network[J]. Information Technology Journal, 2011, 10:883-888.
- [7] Z C Zhang, X Guan, Y He. Study on Radar Emitter Recognition Signal Based on Rough Sets and RBF Neural Network[C]//Proceedings of the 8th International Conference on Machine Learning and Cybernetics, Baoding, China, 2009, 2:1225-1230.
- [8] L Li, H Ji, L Wang, Specific Radar Emitter Recognition Based on Wavelet Packer Transform and Probabilistic SVM[C]//Proceedings of the 2009 IEEE International Conference on Information and Automation, Zhuhai/Macau, China, 2009:1308-1313.
- [9] Christopher M Bishop. Pattern Recognition and Machine Learning : Information Science and Statistics[M]. New York:Springer Science Business Media, 2007.
- [10] Kevin P Murphy. Machine Learning: A Probabilistic Perspective[M]. Massachusetts: The MIT Press, 2012.
- [11] Y Chen, J Yang, Trappe W, et al. Detecting and Localizing Identity-Based Attacks in Wireless and Sensor Networks[J]. IEEE Transactions on Vehicular Technology, 2010, 59(5):2418 - 2434.
- [12] P lingras, C West. Interval set Clustering of Web Users with Rough k-means[J]. Journal of Intelligent Information Systems, 2004, 23(1):5-16.
- [13] B Walczak, D L. Massart. Rough sets theory[J]. Chemometrics and Intelligent Laboratory Systems, 1999, 47(1):1-16.
- [14] 安利平. 基于粗糙集理论的多属性决策分析[M]. 北京: 科学出版社, 2008
- [15] AN Liping. The Multi-Attribute Decision and Analysis Based on Rough Sets Theory[M]. Beijing: The Science Press, 2008. (in Chinese)
- [15] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012.
- [15] LI Hang. Stochastic Learning Methods[M]. Beijing: The Tsinghua University Press, 2012. (in Chinese)
- [16] Y Freund, R Schapire. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting[J]. Journal of Computer and System Sciences, 1995, 55(1):119-139.
- [17] J Zhu, H Zou, S Rosset, et al. Multi-class AdaBoost[J]. Statistics and Its Interface, 2009, 2(3):349-360.

(编辑: 姚树峰)