

一种自整定权值的多分类器融合方法

米爱中^{1,2}, 郝红卫², 郑雪峰², 涂序彦²

(1. 河南理工大学计算机科学与技术学院, 河南焦作 454000; 2. 北京科技大学信息工程学院, 北京 100083)

摘 要: 本文提出一种自整定权值的融合方法. 该方法使用混淆矩阵来衡量分类器性能, 并根据分类器输出情况自适应地为各分类器赋予权值, 可靠的决策结果获得较大的权值, 从而提高决策模板的可信度. 对于易被错误分类的样本, 在利用其与决策模板的相似性信息的同时, 结合它周围的训练样本信息做出判断. 通过与 DT 方法在 KDD '99 入侵检测数据集和 UCI 数据库中的 8 个数据集上的实验对比, 表明本文方法具有更好的分类性能.

关键词: 多分类器系统; 决策融合; 混淆矩阵; 决策模板

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2009) 11-2604-06

A Method of Multiple Classifier Fusion with Self-Adjusting Weights

MI Ai-zhong^{1,2}, HAO Hong-wei², ZHENG Xue-feng², TU Xu-yan²

(1. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo, Henan 454000, China;

2. School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: A fusion method with self-adjusting weights is proposed, which measures the classifier performance by the confusion matrix, and self-adaptively assigns weights to classifiers based on their outputs. Bigger weights are assigned to reliable outputs so that the decision templates are more credible. For a sample which is prone to be misclassified, besides the similarity between it and the decision templates, the information of the training samples around it are included to make a decision. Experiments were done on the KDD '99 intrusion detection dataset and 8 datasets from the database UCI to compare the proposed method with the DT method. The experimental results show the presented method has a better classification performance.

Key words: multiple classifier systems; decision fusion; confusion matrix; decision template

1 引言

传统的模式识别系统常常只用一个分类器进行识别, 因此, 就需要这个分类器在所有的样本特征上都有很好的区分能力, 这往往难以实现. 近年来, 研究人员逐渐发现不同分类器之间的互补性很强. 在这一发现的驱动下, 多分类器系统 (Multiple Classifier Systems, MCS) 受到了越来越多的关注并迅速发展成为模式识别领域的一个研究热点, 大量的实验和应用证明: 将多个分类器的决策结果按一定规则融合在一起, 往往可以得到比其中最优分类器还要好的性能. 目前, 基于多分类器系统进行模式识别已经在许多应用领域获得了广泛应用^[1,2].

多分类器系统中研究的一个根本问题是如何将多个分类器的输出结果按某种方式融合在一起来达到“共识”. 根据分类器不同的输出结果形式, 可将多分类器融合分为三个层次, 即抽象层 (abstract level)、排序层 (rank

level) 和度量层 (measurement level)^[3].

抽象层也称为符号层或决策层, 每个分类器的输出结果是由该分类器所判断的输入模式所属类别的编号. 典型的抽象层融合方法有行为知识空间法 (BKS: Behavior Knowledge Space)^[4] 和多数投票法 (Majority Voting) 及其各种衍生方法. 排序层, 每个分类器按输入模式属于各类别的可能性大小给出所有类别编号的一个排序. 排序层融合方法如 Borda 记数法 (Borda Count)^[5] 和双目标融合方法^[6].

度量层, 每个分类器的输出是一个由输入模式属于各类别可能性度量值所组成的向量. 不同分类器使用的度量值的形式和物理含义是不同的: 对于 Bayes 分类器而言, 该度量是样本对各类别的后验概率; 对一些距离分类器而言, 该度量为某种距离度量 (如欧氏距离); 对另一些分类器而言, 为某种相似性度量 (例如向量间的夹角). 度量层融合保证了分类器输出信息的完整性, 因此可以达到更精确的分类效果. 度量层融合方法如:

收稿日期: 2008-05-08; 修回日期: 2008-09-10

基金项目: 国家自然科学基金 (No. 60675006); “十一五” 国家科技支撑计划 (No. 2006BAI03A09); 河南省教育厅自然科学研究计划 (No. 2008A520010)

乘法(Product)、求和法(Sum)、均值法(Mean)、最大值法(Max)、最小值法(Min)、中值法(Median)^[2]、决策模板法(Decision Templates, DT)^[7]和 D-S 理论法(Dempster-Shafer theory)^[8]等。

DT方法是一种简单直观而且非常有效的度量层的多分类器融合方法。该方法具有以下优点^[9]:训练简单;与基于概率理论的组合方法相比,它不需要严格的假设条件;对训练集合大小不是很敏感,不易导致过训练(overtraining)的情况发生;分类过程计算量小,速度快。

但是DT方法存在两个问题:(1)其使用的决策模板只是同一类别所有决策轮廓的简单平均,没有充分体现各个分类器的性能差异;(2)仅利用了决策模板的分类信息,而其他训练样本的信息没有利用。

针对DT方法存在的以上问题,本文提出了一种自整定权值的决策模板方法SWDT(Self-adjusting weighted DT)。该方法使用混淆矩阵衡量各分类器的性能差异,对决策轮廓进行加权变换后构造决策模板,对易于被分类错误的样本,在利用其与决策模板的相似性信息的同时,结合该样本周围的训练样本信息做出判断。

2 决策轮廓

设 $X = [x_1, x_2, \dots, x_n]^T$ 是表示一个输入模式的 n 维特征向量, R^n 表示 n 维特征空间, $\Omega = \{c_1, c_2, \dots, c_m\}$ 是所有可能类别的集合, $C = \{C_1, C_2, \dots, C_l\}$ 为选取的进行决策融合的分类器的集合,对于一个输入模式 $X \in R^n$,第 i 个分类器的度量层输出记为:

$$C_i(X) = [c_{i,1}(X), c_{i,2}(X), \dots, c_{i,m}(X)]^T \quad (1)$$

其中 $c_{i,j}(X)$, $i=1, 2, \dots, l, j=1, 2, \dots, m$ 表示分类器 C_i 认为 X 属于类别 c_j 的可能性度量值。

l 个分类器的决策融合后的结果表示为:

$$C(X) = F(C_1(X), C_2(X), \dots, C_l(X)) \quad (2)$$

其中 F 为使用的融合规则。

所有分类器的输出可以表示为一个 $l \times m$ 矩阵形式的决策轮廓(Decision Profile)^[7] $DP(X)$:

$$DP(X) = \begin{bmatrix} c_{1,1}(X) & \dots & c_{1,j}(X) & \dots & c_{1,m}(X) \\ \dots & \dots & \dots & \dots & \dots \\ c_{i,1}(X) & \dots & c_{i,j}(X) & \dots & c_{i,m}(X) \\ \dots & \dots & \dots & \dots & \dots \\ c_{l,1}(X) & \dots & c_{l,j}(X) & \dots & c_{l,m}(X) \end{bmatrix} \quad (3)$$

$DP(X)$ 的第 i 行即是式(1)给出的第 i 个分类器的度量层输出 $C_i(X)$, 而第 j 列是 l 个分类器认为输入模式 X 属于类别 c_j 的可能性度量值。融合结果 $C(X)$ 同样是度量层表示的 m 维向量形式,记为:

$$C(X) = [d_1(X), d_2(X), \dots, d_m(X)]^T \quad (4)$$

其中 $d_i(X)$, $i=1, 2, \dots, m$ 表示融合后 X 属于类别 c_i

的可能性度量值。

获得式(4)的融合结果后,还需要使用某种规则来判断输入模式所属的类别,通常使用取最大值的方法,

即若 $d_k(X) = \max_{i=1}^m d_i(X)$, 则认为 $X \in c_k$ 。

简单融合规则(乘法、求和法、均值法、最大值法、最小值法、中值法)仅对决策轮廓的各列分别进行操作来获得系统的输出。以均值法为例:

$$d_j(X) = \frac{1}{l} \sum_{i=1}^l c_{i,j}(X), j=1, 2, \dots, m \quad (5)$$

该方法对决策轮廓 $DP(X)$ 的每一列求平均值,得到融合结果 $C(X)$ 。D-S 理论法虽然使用整个决策轮廓矩阵,但是丢弃了一些可能有用的上下文信息。而DT方法则是将这两种做法结合在了一起。

3 SWDT方法描述

在训练阶段,DT方法根据各分类器的输出为每一类别计算训练集合 Z 中所有属于该类别样本的决策轮廓的均值,这个均值就是该类别的决策模板。然后通过比较输入样本的决策轮廓与各个决策模板的相似性,来确定输入样本的类别。文献[7]中采用多种相似性度量方法,将DT方法与已有的各种分类器组合方法进行实验对比,证明采用整体型度量的DT方法优于其他方法。

3.1 基本思想

SWDT方法的基本思想:(1)由于各个分类器的性能存在差异,即使是同一个分类器对数据集中不同类别的数据的区分能力也是不同的。当分类器的输出保留了类别详细相关信息时,DT方法性能会很好,而当分类器对输入空间的某些特征非常敏感从而导致输出空间中某些类别信息发生很大改变时,容易引起该方法的性能显著下降。针对这一问题,SWDT方法使用混淆矩阵衡量各分类器的性能,根据分类器输出的具体情况自适应地为各分类器赋予权值,性能好的分类器的输出在决策模板的构造过程中占有较大的比重,从而获得更加可信的决策模板,提高分类精度。(2)对于一些样本来说,它们即使与同类别的样本数据相比也有明显的差异,这些样本往往是各个类别样本中的异类(outlier)。它们的决策轮廓虽然与大部分的样本决策轮廓有明显的不同,但是因为数量少,在DT方法中,计算所得决策模板与其就有很大的差异。而且DT方法仅比较决策轮廓与决策模板的相似性,使得各类别中的一些样本,因为其决策轮廓与对应决策模板相似性很小或者处于多个类别重叠区域而容易被错误分类。针对这一问题,SWDT方法分类时借助测试样本附近各训练样本的信息,利用寻找若干最近邻的方法,将训练样

本信息与计算决策模板的相似性结合起来,从而在一定程度上避免完全依靠决策模板所造成的偏差,使最终的类别判断更可靠.

3.2 具体步骤

决策轮廓的加权变换过程如下:

第 k 个分类器 C_k 的分类误差可以用一个 $m \times m$ 的混淆矩阵 (Confusion Matrix) CM^k 表示如下^[10]:

$$CM^k = \begin{bmatrix} n_{1,1}^k & n_{1,2}^k & \dots & n_{1,m}^k \\ n_{2,1}^k & n_{2,2}^k & \dots & n_{2,m}^k \\ \dots & \dots & \dots & \dots \\ n_{m,1}^k & n_{m,2}^k & \dots & n_{m,m}^k \end{bmatrix} \quad (6)$$

其中,元素 $n_{i,j}^k, i, j = 1, 2, \dots, m$ 表示训练样本中第 i 类样本被分类器 C_k 识别为第 j 类的个数,该矩阵的第 i 行的和表示训练样本中第 i 类的样本总数,而第 j 列的和表示训练样本中被该分类器识别为第 j 类的样本总数,对角线元素 $n_{i,i}^k$ 表示训练样本中第 i 类的样本被该分类器正确识别的个数.设训练样本的总数为 N ,将混淆矩阵除以 N 加以规格化,此时其各元素的含义变为对应的百分比.规格化的混淆矩阵表示为:

$$CM^{k/N} = \begin{bmatrix} n_{1,1}^{k/N} & n_{1,2}^{k/N} & \dots & n_{1,m}^{k/N} \\ n_{2,1}^{k/N} & n_{2,2}^{k/N} & \dots & n_{2,m}^{k/N} \\ \dots & \dots & \dots & \dots \\ n_{m,1}^{k/N} & n_{m,2}^{k/N} & \dots & n_{m,m}^{k/N} \end{bmatrix} \quad (7)$$

此时,分类器 C_k 的输出向量(如式(1)所示)的可信度可以用 $n_{h,h}^{k/N}$ 进行衡量,其中 h 的取值满足条件:

$c_{k,h} = \max_{j=1}^m (c_{k,j})$. 这样分类器 C_k 的可信输出可表示为:

$$C_k(X) = n_{h,h}^{k/N} * C_k(X) \quad (8)$$

按照式(8)计算所有分类器的可信输出向量,得到新的决策轮廓 $DP(X)$:

$$DP(X) = \begin{bmatrix} c_{1,1}(X) & \dots & c_{1,j}(X) & \dots & c_{1,m}(X) \\ \dots & \dots & \dots & \dots & \dots \\ c_{i,1}(X) & \dots & c_{i,j}(X) & \dots & c_{i,m}(X) \\ \dots & \dots & \dots & \dots & \dots \\ c_{l,1}(X) & \dots & c_{l,j}(X) & \dots & c_{l,m}(X) \end{bmatrix} \quad (9)$$

使用 $DP(X)$ 代替 $DP(X)$,采用欧氏距离作为相似性的度量,SWDT方法描述如下:

(1) 训练过程

用每个分类器对训练样本进行分类,获得各个分类器的混淆矩阵 $CM^k, k = 1, 2, \dots, l$,构造对应的决策轮廓 $DP(X)$ 的集合 D ,并在训练集合 Z 上计算出对应的决策模板 $DT_i, i = 1, 2, \dots, m$,计算式如下:

$$DT_i = \frac{1}{N_i} DP(z_j), z_j \in Z, z_j \in \omega_i \quad (10)$$

其中 z_j 表示训练集合 Z 中属于类别 ω_i 的样本, N_i 表示 z_j 的个数;

对任一训练样本 $P \in Z$,计算其决策轮廓 $DP(P)$ 和 DT_i 之间的欧氏距离的平方值 $d_E(DP(P), DT_i)$,计算式如下:

$$d_E(DP(P), DT_i) = \sum_{j=1}^m \sum_{k=1}^l (c_{k,j}(P) - dt_i(k,j))^2 \quad (11)$$

其中 $dt_i(k,j)$ 表示 DT_i 第 k 行,第 j 列元素;

计算训练样本 P 属于各类别的可能性度量值:

$$d_i(P) = 1 - \frac{1}{l \times m} d_E(DP(P), DT_i) \quad (12)$$

若 $d_K(P) = \max_{i=1}^m d_i(P)$,则认为 $P \in \omega_K$;

重复步骤 (1),直至将所有的训练样本都分类完毕.根据分类结果,获得判断类别与实际类别不一致的训练样本所对应的决策轮廓集合 $D_w (D_w \subseteq D)$;

设 D_w 中所有元素的均值,作为一个附加的决策模板,记为 DT_{m+1} ,并使用集合 D_w 训练一个 k -最近邻 (k -NN) 分类器 C_{km} ;

返回所有决策模板 $DT_i, i = 1, 2, \dots, m+1$,混淆矩阵 $CM^k, k = 1, 2, \dots, l$ 和分类器 C_{km} .

(2) 分类过程

对一个输入模式 X ,利用训练中获得的混淆矩阵构造其决策轮廓 $DP(X)$;

由式(11)计算 $DP(X)$ 和 DT_i 之间的欧氏距离的平方值 $d_E(DP(X), DT_i)$,然后由式(12)计算样本 X 属于各类别的可能性度量值 $d_i(X), i = 1, 2, \dots, m+1$;

判断输入模式 X 的类别:

a. 设 $d_K(X) = \max_{i=1}^{m+1} (d_i(X))$,如果 $K = m$ 则认为 $X \in \omega_K$;

b. 否则,使用 C_{km} 对 X 进行分类,设其度量层输出为 $[c_1(X), c_2(X), \dots, c_m(X)]^T$,如果 $d_K(X) = \max_{i=1}^m (d_i(X) + c_i(X))$,则 $X \in \omega_K$.

混淆矩阵是通过训练样本集上的统计信息获得,然后根据各分类器判断的类别自适应地赋予分类器输出向量不同的权值,这样使得决策模板中不同分类器以及同一分类器对不同类别数据的决策占有不同的比重,越可靠的输出占有的比例越大,使得决策模板更加可信.权值依赖训练样本的先验信息和分类器对当前样本的决策结果自主地获得,因此这是一种权值自适应的过程.使用训练集中被多分类器系统错误分类的样本构造了一个附加的决策模板,当输入样本距离这个模板的中心最近时,有理由认为该样本也是使用决策模板容易被错误分类的,这时候利用最近邻规则,

将该样本周围的训练样本信息和该样本与各个模板的距离信息结合起来做出类别判断,从而提高准确度。

4 实验

本文实验使用 Matlab6.5 编程实现,在具体代码编写过程中,使用了模式识别工具箱“PRTools4”^[11]。实验中使用的 k -最近邻(k -NN)分类器的代码来自于该工具箱,代码中对参数 k 使用留一法(leave-one-out)自动优化选择,分类器输出度量为后验概率。

4.1 使用 KDD '99 数据

所使用的样本数据来自于 KDD '99 的入侵检测数据集^[12],这是目前入侵检测领域比较权威的测试数据^[13]。该数据集中的元素是把网络上收集的 TCP/IP 包进行预处理后所获得的连接模式,其中所包含的特征分为三类:本质(intrinsic)特征、通信量(traffic)特征和内容(content)特征。每个连接模式使用 41 维特征向量表示,所有连接都属于五个类别中的一个(正常、拒绝服务攻击 DoS、远程未授权访问攻击 R2L、非授权特权攻击 U2R、监视及扫描攻击 Probing)。

首先从两个具有正确类别标号的数据集中,分别抽取与最常用的 ftp 服务相关的连接模式获得一组训练集和测试集。对选取的样本数据进行如下处理:维数消减,丢弃那些值始终为常量的特征;符号型特征值量化;将所有特征值使用线性规格化方法处理成 $[0,1]$ 之间的数。

处理后获得的这组数据用 ftp5c 表示,然后把这组数据集中的四种入侵类型归为一个异常类,从而使数据集转化为两类别数据,这组两类别数据用 ftp2c 表示。

采用类似步骤,再分别抽取与 http 服务相关的连接模式作为样本数据。同样获得两组数据,名称为 http4c 和 http2c。前一组数据集为四类别数据,后一组则为两类别数据。由于与 http 服务相关的连接模式数量很多,选取样本时增加限定条件:连接持续时间(duration)不为零。四组数据的说明见表 1,其中各组数据中的集合 A 表示训练集,B 表示测试集。

表 1 KDD 数据集说明

数据集	样本数	类别数	特征数		
			本质特征	通信量特征	内容特征
ftp5c	A 800	5	4	19	6
	B 5212				
ftp2c	A 800	2	4	19	5
	B 5212				
http4c	A 410	4	4	19	5
	B 3380				
http2c	A 410	2	4	19	5
	B 3380				

对于四组数据集,在每组数据的 A 集合上对应每

一类特征训练一个 k -NN 分类器,用三个分类器构成分类器集合。两种方法的测试结果如表 2 所示。

表 2 KDD 数据集上的性能

数据集	错误率 (%)	
	DT	SWDT
ftp5c	5.794	5.411
ftp2c	1.055	1.036
http4c	3.047	0.237
http2c	0.237	0.148

从表 2 的实验结果可以看到,在四个数据集上,SWDT 方法的性能都要好于 DT 方法。尤其是在两个类别比较多的数据集 ftp5c 和 http4c 上,该方法的错误率下降的更加明显,如图 1 所示。这是因为类别越多,在决策模板中所反应的分类器对各个类别的性能差异越明显,决策模板的可信程度就越高,而此时分类错误的样本与其他样本的差别也就越明显,结合输入样本周围的训练样本信息,与计算的决策模板的相似性之间的互补性也就更好。实验结果说明 SWDT 方法对提高分类性能是有效的。




图 1 KDD 数据集上的性能对比

4.2 使用 UCI 数据

为充分验证算法的性能,本文还选取了 UCI 机器学习数据库^[14]中的 8 个数据集进行实验分析。UCI 数据库是国际上常用的一个标准测试数据库,含有多个应用领域的若干数据集。因算法研究的需要,选择的 8 个数据集中的特征均为数字量,且无错误和无特征值缺失。所有特征值经过规格化方法转换,处理成 $[0,1]$ 之间的数。数据集的说明见表 3,其中各数据集的名称仅使用了 UCI 数据库中数据集名称的首个单词。

表 3 UCI 数据集说明

数据集	样本数	特征数	类别数
glass	214	9	6
bupa	345	6	2
pima	768	8	2
thyroid	215	5	3
wine	178	13	3
German	1000	24	2
heart	270	13	2
vehicle	846	18	4

8 个 UCI 数据集中没有训练集和测试集之分,因此采用交叉验证(cross validation)的方法:采用 6 次交叉验证,将数据集划分类别分布相似、大小基本相同、互不相交的 6 个样本子集,每次取其中的 5 个作为两种方法的训练集,剩余的 1 个作为测试集.在每个样本子集上训练一个 k -NN 分类器,选定作为训练集的 5 个样本子集后,与之对应 5 个 k -NN 分类器组成分类器集合进行实验测试.实验结果为 6 次交叉验证的均值,如表 4 所示.从表 4 的实验结果可以看到,对于 8 个测试数据集,SWDT 方法在 7 个数据集上的性能要好于 DT 方法.

表 4 UCI 数据集上的性能

数据集	错误率(%)	
	DT	SWDT
glass	41.367	42.538
bupa	24.751	20.526
pima	26.042	23.828
thyroid	14.484	3.320
wine	6.825	2.857
German	27.564	24.154
heart	17.407	15.926
vehicle	33.394	26.195

同样可以看到在类别数较多的数据集 thyroid, wine, vehicle 上,该方法的性能提高更加明显,如图 2 所示.其中 glass 数据集是一个例外情况,这主要是因为该数据集中样本数较少,而类别比较多,且不同类别的样本分布具有很大的差异.在这种情况下,以同类样本的均值作为该类样本的代表会导致很大的误差,DT 方法的性能同样也说明了这一点,而 SWDT 方法需要再划分出一个附加的决策模板,所以会导致性能进一步下降.但是,从图 2 可以看到,在 glass 数据集上,相对于 DT 方法,SWDT 方法的错误率增加并不是非常显著(为 2.83%),而在其他数据集上,该方法错误率下降的最小幅度为 8.5%(pima 数据集).




图 2 UCI 数据集上的性能对比

需要说明一点,本文实验中采用的是多个 k -NN 分类器,当 MCS 由多种不同分类器组成时,由于各分类器输出的物理意义和尺度不同,无论是 DT 还是 SWDT 方法的性能都会受到明显的影响.此时需要将各分类器的输出转化为统一的可信度,转化方法可参见文献[15].

5 结论

本文提出一种自整定权值的多分类器融合方法,该方法使用混淆矩阵衡量分类器性能,并根据分类器输出的具体情况自适应地为各分类器赋予权值,使得在决策模板中不同分类器以及同一分类器对不同类别数据的决策占有不同的比重,越可靠的输出占有的比例越大,从而获得更可信的决策模板.对易于被错误分类的样本,在利用其与决策模板的相似性信息的同时,结合该样本周围的训练样本信息做出判断.通过在多个数据集上与 DT 方法的实验对比,验证了本文方法具有更好的分类性能,且具有一定通用性.

参考文献:

- [1] Rahman A F R, Fairhurst M C. Multiple classifier decision combination strategies for character recognition: a review [J]. International Journal on Document Analysis and Recognition (IJ DAR), 2003, 5(4): 166 - 194.
- [2] Jain A K, Duin R P W, Mao Jianchang. Statistical pattern recognition: a review [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(1): 4 - 37.
- [3] Altinçay H, Demireklera M. Undesirable effects of output normalization in multiple classifier systems [J]. Pattern Recognition Letters, 2003, 24(9 - 10): 1163 - 1170.
- [4] Raudys š, Roli F. The behavior knowledge space fusion method: analysis of generalization error and strategies for performance improvement [A]. Proceedings of 4th International Workshop on Multiple Classifier Systems (MCS) [C]. Lecture Notes in Computer Science (LNCS), Berlin: Springer-Verlag Press, 2003. 2709. 55 - 64.
- [5] Parker J R. Rank and response combination from confusion matrix data [J]. Information Fusion, 2001, 2(2): 113 - 120.
- [6] 刘明,袁保宗,苗振江.一种双目标排序层分类器融合方法[J].自动化学报,2007,33(12):1276 - 1282.
Liu Ming, Yuan Bao-zong, Miao Zhen-jiang. A double-objective rank level classifier fusion method [J]. Acta Automatica Sinica, 2007, 33(12): 1276 - 1282. (in Chinese)
- [7] Kuncheva L I, Bezdek J C, Duin R P W. Decision templates for multiple classifier fusion: An experimental comparison [J]. Pattern Recognition, 2001, 34(2): 299 - 314.
- [8] Thierry D. A neural network classifier based on Dempster-Shafer theory [J]. IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2000, 30(2): 131 - 150.
- [9] Valet L, Ramasso E, Teyssier S. Quality evaluation of insulating parts by fusion of classifiers issued from tomographic images [J]. Information Fusion, 2008, 9(2): 211 - 222.
- [10] Xu Lei, Krzyzak A, Suen Ching Y. Methods of combining

multiple classifiers and their applications to handwriting recognition[J]. IEEE Transactions on System, Man, and Cybernetics, 1992, 22(3): 418 - 435.

- [11] Duin R P W, Juszczak P, Paclik P, et al. PRTools4, A Matlab Toolbox for Pattern Recognition[CP/OL]. Delft University of Technology, 2004.
- [12] University of California. KDD Cup 1999 data [DB/OL]. <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>, 1999.
- [13] 罗敏, 王丽娜, 张焕国. 基于无监督聚类的入侵检测方法[J]. 电子学报, 2003, 31(11): 1713 - 1716.
Luo Min, Wang Li-na, Zhang Huan-guo. An unsupervised clustering-based intrusion detection method[J]. Acta Electronica Sinica, 2003, 31(11): 1713 - 1716. (in Chinese)
- [14] Newman D J, Hettich S, Blake C L, et al. UCI repository of machine learning databases [DB/OL]. <http://www.ics.uci.edu/~mllearn/MLRepository.html>, Irvine, CA: University of California, 1998.
- [15] Liu Chenglin, Hao Hongwei, Hiroshi Sako. Confidence transformation for combining classifiers [J]. Pattern Analysis and Application, 2004, 7(1): 2 - 17.

作者简介:



米爱中 男, 1977 年生于河南焦作, 北京科技大学信息工程学院博士研究生, 河南理工大学计算机科学与技术学院讲师, 感兴趣的领域为人工生命、模式识别. E-mail: miaizhong@163.com



涂序彦 男, 1935 年生于江西南昌, 现任中国人工智能学会指导委员会主席, 北京科技大学教授, 博士生导师, 兼任北京邮电大学、北京理工大学教授、博士生导师, 主要研究方向为大系统控制、人工智能、人工生命、智能管理等. E-mail: tuxuyan@126.com

电子学报

2009 年第 11 期 Acta Electronica Sinica No. 11 2009

(总第 319 期) (Monthly) (Series No. 319)

主管单位	中国科学技术协会	China Association for Science and Technology
主办单位	中国电子学会	Published by the Chinese Institute of Electronics, Beijing
编辑	《电子学报》编辑委员会	Edited by Editorial Board of Acta Electronica Sinica
主编	王守觉	Chief Editor: WANG Shou-jue
总编辑	刘力	Director: LIU Li
通信处	北京 165 信箱 (邮政编码 100036)	Add: Editorial Office of Acta Electronica Sinica (P O Box 165, Beijing 100036, China)
电话	(010) 68279116, 68285082	Tel: 86-10-68279116, 68285082
传真	(010) 68173796	Fax: 86-10-68173796

Home page: <http://www.ejournal.org.cn>; <http://dzxu.chinajournal.net.cn>

Email: new@ejournal.org.cn; wanghui@ejournal.org.cn

排版印刷 北京墨禹天成印刷有限公司 Printed by Moyutiancheng Co. Ltd., Beijing, China

国内总发行 北京市报刊发行局 Distributed by

Domestic: Beijing Baokan Faxingju, China

国外总发行 中国国际图书贸易总公司 Foreign: China International Book Trading Corporation

国内订购处 全国各邮电局 Subscription Office — All Local Post Offices in China

国内统一刊号: CN11 - 2087/ TN

邮发代号(国内/国外): 2 - 891/M436

国内定价 40.00

