

基于混淆矩阵和 Fisher 准则构造层次化分类器*

张 静[†], 宋 锐, 郁文贤, 夏胜平, 胡卫东

(国防科学技术大学 ATR 重点实验室, 湖南 长沙 410073)

Construction of Hierarchical Classifiers Based on the Confusion Matrix and Fisher's Principle

ZHANG Jing[†], SONG Rui, YU Wen-Xian, XIA Sheng-Ping, HU Wei-Dong

(State Laboratory of Automatic Target Recognition, National University of Defense Technology, Changsha 410073, China)

+ Corresponding author: Phn: +86-10-66356573, Fax: +86-10-64836117, E-mail: ben_bbj@126.com

Received 2004-03-31; Accepted 2004-10-09

Zhang J, Song R, Yu WX, Xia SP, Hu WD. Construction of hierarchical classifiers based on the confusion matrix and Fisher's principle. *Journal of Software*, 2005,16(9):1560-1567. DOI: 10.1360/jos161560

Abstract: Determination of the hierarchical relationship and the objective patterns of sub-classifiers is a primary problem in the construction of a hierarchical classifier. In this paper, a method focusing on the similarities between patterns is proposed to generate a hierarchical structure automatically. Firstly, a similarity measurement utilizing the confusion matrix is advanced to avoid the drawbacks of the traditional measurements, such as high computation costs and invalidity of preliminary conditions. Then abiding by Fisher's Principle, a Patterns' Similarity Relationship Analyzing Machine (PSRAM), which is integrated with the supervised and unsupervised pattern recombination methods, is designed to adaptively construct the structure of a hierarchical classifier. Various tests are testified that the proposed method is effective and practical, and it can prominently improve the performance and robustness of the hierarchical classifier.

Key words: hierarchical classifier; similarity measurement; patterns' similarity relationship analysis machine; Fisher's principle; adaptive pattern combination

摘 要: 构造层次化分类器的首要环节是确定各个子分类器的层属关系及其内部组成.从模式间的相似关系入手,实现了一种自动产生层次化分类器结构的方法.为了描述模式间的相似关系,首先提出利用混淆矩阵度量相似性的思路与方法,避免了现有常用度量方法计算量大、假设条件难以成立的不足.进而遵循 Fisher 准则,设计并实现了模式相似关系分析机(patterns' similarity relationship analyzing machine,简称 PSRAM),将有师指派和无师自组两种常用的模式重组方法有机结合起来,自适应地产生层次化分类器结构.大量测试证实,该方法有效、实用,可以显著地提高分类器的识别性能和稳健性.

关键词: 层次化分类器;相似性度量;模式相似关系分析机;Fisher 准则;自适应模式组合

* 作者简介: 张静(1977 -),女,河北唐山人,博士,助理研究员,主要研究领域为机器学习,雷达目标识别,建模与仿真,武器装备论证;宋锐(1975 -),男,博士,讲师,主要研究领域为雷达目标识别,系统集成;郁文贤(1964 -),男,博士,教授,博士生导师,主要研究领域为智能信号处理,目标识别,信息融合;夏胜平(1969 -),男,博士,副教授,主要研究领域为雷达目标识别,机器学习,智能信号处理;胡卫东(1967 -),男,博士,教授,主要研究领域为信息融合,目标识别,智能信号处理,系统集成.

中图法分类号: TP18 文献标识码: A

层次化分类器由一系列子分类器按照一定的组织结构和层属关系共同构成.它将复杂的多模式识别问题分解成多个不同层次上、相对简单的针对较少模式的识别问题,从而达到降低分类难度、分而治之的目的^[1-3].设计层次化分类器,首先需要解决多模式的重新组合问题,确定各个子分类器的层属关系及其内部组成^[1,2].目前常用的方法可分为两种思路:有师指派,即领域专家根据背景知识确定模式重组方案;无师自组,即通过不同的聚类算法产生模式组合关系.然而,前者常存在结构单调、主观性强等缺陷,而后者则存在不可控因素多、性能不稳定等不足,需要将两种思想有机地结合起来,建立合理的层次化分类器结构^[1,2].

Fisher 准则^[4]指出,当模式样本具有最小类内距离和最大类间距离时,将具有最佳的分类效果.着眼于设计合理的层次化分类器结构,提高重聚类后的类内一致性和类间可分性,本文提出并实现了一种基于模式间相似关系(similarity relationship,简称 SR)自适应地构造分类器层次结构的方法,以模式在判决域中表现出的相似性为切入点,基于 Fisher 准则产生模式组合的依据和准则.该方法有效地综合了有师和无师方法,具有原理简单、可实施性强、稳定性高的优点.

本文第 1 节首先分析了多种常用的模式间相似性度量方法及其不足,然后设计了一种利用混淆矩阵对相似性进行度量的方法.第 2 节在对有师和无师两类模式重组方法的优缺点进行分析的基础上,基于上述度量,采用模块化思想设计了模式相似关系分析机 PSRAM(patterns' similarity relationship analyzing machine),自适应建立层次化分类器的组织结构.第 3 节通过多个雷达目标识别场景中的大量实测数据,对本文提出的方法与常规层次化方法进行了综合测试和比较分析,验证了本文所提出方法的有效性、实用性和稳定性.第 4 节对本文工作进行了总结说明.

1 模式间相似性的度量

1.1 常用的模式间相似性度量方法

在模式识别中,各个类型之间通常具有不同程度的相似性,这决定了识别问题的难度和判决结果的质量.当相似的模式种类少且相似程度低时,模式之间的可分性较好,有利于识别问题的完成;而当相似的模式种类多且相似程度高时,模式之间的可分性差,进行识别的难度就高.因此,需要建立对模式间相似性进行度量的方法和准则,掌握具体问题背景下各个模式之间的相似程度,从而指导分类器的构造过程.

相似性属于抽象概念,难以直接定量求取.现有的方法主要从下面 3 个角度^[1,2,4]对其进行描述:基于特征空间几何距离的方法,如离差矩阵 S_W , S_B , S_T 及其变换 $Tr[S_W^{-1}S_B]$, $|S_B|/|S_W|$ 等;基于模式概率分布的方法,如 Bhattacharyya 判据 J_B 、Chernoff 判据 J_C 、散度判据 J_D 等,以及基于后验概率的方法,如 Shannon 熵可分性判据 J_H 和计算更为简便的广义熵判据等.上述各种判据能够从不同角度描述模式之间的相似性,在理论分析与实际应用中发挥了一定作用.

但是在实际应用中,度量模式间相似性的方法应同时达到前提条件的可满足性和计算方法的可实施性这两个要求,而上述方法却不具备这样的性质^[5].例如,当样本数量多、特征空间维数高时,基于特征空间距离测度的判据运算代价相当大,且难以完全避免特征相关所造成的影响;基于模式概率分布的判据要求模式概率分布已知,这一前提条件在实际问题中往往难以满足,通常只能建立在假设条件基础上;基于后验概率的判据,遵循熵的基本原则,更适合于刻画整个聚类问题的不确定性,而非非两两模式之间的相似性.针对上述问题,本文利用混淆矩阵,设计了一种简捷、实用的度量模式间相似性的方法.

1.2 基于混淆矩阵度量模式间相似性

1.2.1 混淆矩阵

混淆矩阵是模式识别领域中一种常用的表达形式.它描绘样本数据的真实属性与识别结果类型之间的关系,是评价分类器性能的一种常用方法.假设对于 N 类模式的分类任务,识别数据集 D 包括 T_0 个样本,每类模式

分别含有 T_i 个数据 ($i = 1, \dots, N$). 采用某种识别算法构造分类器 C , cm_{ij} 表示第 i 类模式被分类器 C 判断成第 j 类模式的数据占第 i 类模式样本总数的百分率, 则可得到 $N \times N$ 维混淆矩阵 $CM(C, D)$:

$$CM(C, D) = \begin{pmatrix} cm_{11} & cm_{21} & \dots & cm_{i1} & \dots & cm_{N1} \\ cm_{12} & cm_{22} & \dots & cm_{i2} & \dots & cm_{N2} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ cm_{1i} & cm_{2i} & \dots & cm_{ii} & \dots & cm_{Ni} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ cm_{1N} & cm_{2N} & \dots & cm_{iN} & \dots & cm_{NN} \end{pmatrix} \quad (1)$$

混淆矩阵中元素的行下标对应目标的真实属性, 列下标对应分类器产生的识别属性. 对角线元素表示各模式能够被分类器 C 正确识别的百分率, 而非对角线元素则表示发生错误判断的百分率.

通过混淆矩阵, 可以获得分类器的正确识别率和错误识别率:

各模式正确识别率:

$$R_i = cm_{ii}, \quad i = 1, \dots, N \quad (2)$$

平均正确识别率:

$$R_A = \sum_{i=1}^N (cm_{ii} \times T_i) / T_0 \quad (3)$$

各模式错误识别率:

$$W_i = \sum_{j=1, j \neq i}^N cm_{ij} = 1 - cm_{ii} = 1 - R_i \quad (4)$$

平均错误识别率:

$$W_A = \sum_{i=1}^N \sum_{j=1, j \neq i}^N (cm_{ij} \times T_i) / T_0 = 1 - R_A \quad (5)$$

1.2.2 基于混淆矩阵的模式间相似性度量

利用混淆矩阵, 除了可以获得分类器正确/错误识别率等指标以外, 还可以发现那些容易发生错误判断的模式类型. 然而, 由式(2)~式(5)可知, 错误识别率均可以通过正确识别率得到. 这意味着, 人们通常仅利用了混淆矩阵中的 N 个对角线元素, 却忽视了 $N(N-1)$ 个非对角线元素, 损失了其中所蕴含的反映模式之间相似性的丰富信息.

在模式识别过程中, 如果某两种模式之间比较相似, 那么它们的样本就容易被判定为对方类型. 假设模式 i 与模式 j 的相似性强, 而与模式 k 的相似性弱, 那么相对于 c_{ik} 和 c_{ki} 而言, c_{ij} 和 c_{ji} 的取值将会较大, 而 c_{ik} 和 c_{ki} 则较小甚至为 0. 由此, 可以推出下面的结论:

结论. 混淆矩阵行向量 C_i ($i = 1, \dots, N$) 代表了模式 i 的对象在进行分类时对各模式的倾向性.

进而, 分析行向量 C_i 与 C_j 之间的关系, 能够发现模式 i 和模式 j 在判决倾向性上所表现出来的一致性及其悖性. 这从本质上看, 是模式 i 和 j 之间相似性的表现和延伸. 因此, 可以从混淆矩阵入手, 建立某种度量, 描述不同模式间相似性的强弱. C_i 和 C_j 之间的距离测度和矢量夹角, 分别表示了它们之间的空间距离和相关性^[6], 均可被用来度量模式之间的相似性. 若二者相距近, 则相似性强; 若相距远则表明相似性弱. 若二者的夹角小, 也意味着相似性强; 若夹角大则说明相似性弱. 本文以 L_2 范数为例来说明如何基于混淆矩阵进行度量.

由 L_2 测度的定义^[6], 可以得到混淆矩阵 $CM(C, D)$ 的 L_2 测度矩阵 LM_2 . LM_2 为 $N \times N$ 方阵, 其元素 lm_{ij} 与 cm_{ij} , $i, j = 1, \dots, N$ 具有如下关系:

$$lm_{ij} = \begin{cases} 0, & i = j \\ (C_i - C_j)^2 = \sum_{k=1}^N (cm_{ik} - cm_{jk})^2, & i \neq j \end{cases} \quad (6)$$

可见, LM_2 矩阵为一个对角线元素为 0 的对称矩阵. 因此, 为了便于计算, 只需分析其上三角部分的元素, 而将其下三角元素置为 0, 则得到相似性度量矩阵 (similarity measurement matrix, 简称 SMM), 记为 TM_2 . lm_{ij} 取值越

小,说明模式 i 与模式 j 的相似性越强,识别过程中这两类模式之间也就越容易发生错误判断;反之, lm_{ij} 取值越大,模式 i 与模式 j 的相似性就越弱,也就越不容易产生错误判断。

2 模式相似关系分析机 PSRAM

确定各层子分类器的层属关系及其内部组成,是层次化分类器设计的重点和难点。只有合理的层次化结构,才能提高模式重新聚类后的类内一致性和类间可分性,有效达到分而治之的目的,降低分类器构造和维护中的风险与代价。

2.1 常用层次化结构确定方法的不足

确定层次化分类器的组织结构,即对多种模式类型进行重新组合和聚类,既可以按照有师指派方式产生,也可以根据无师自组的方式进行^[2]。有师指派是指领域专家根据相关背景知识,将多个类型分别组合成不同的群体^[3],比如在舰船目标识别中可以根据吨位(大/中/小型)将模式进行重组。无师自组则采用无师聚类的思想设计分类器,由一定量的实验样本数据自动产生组合方案^[5]。可见,有师指派是一种针对问题应用领域进行分析的方法,而无师自组则主要是一种着眼于模式特征域的手段,在实际中这两种方式都具有广泛的应用。

通常,模式识别是基于特征空间进行的^[2]。如果仅根据其应用领域的情况,主观地指定聚类/组合方案,而不考虑模式的特征分布,往往是不够合理的。有师指派产生层次化分类结构就存在这种主观性强、结构单一的问题。而无师自组的方式,由于其运算处理过程自动完成,存在一定的不可控性和较强的不稳定性。为此,需要将两种方法结合起来,使层次化分类器的结构既包含先验信息的指导,也能反映出不同模式在特征空间中的分布情况。

鉴于此,我们设计了一个模式相似关系分析机 PSRAM,自适应地确定层次化分类器的结构。

2.2 模式相似关系分析机 PSRAM

图 1 为 PSRAM 的原理框图。图中实线框表示分析机中各个组成模块,虚线框表示各个处理环节所产生的输出结果。

相似程度描述器 D 也称为预分类器,它是一个计算快捷、易于实现的单分类器,如基本 Bayes 分类器等。预分类器对样本数据进行识别,产生分类的混淆矩阵,从中获取模式相似性指标(如平均正确率 R_A 、错误率 W_A 等)以及相似性度量矩阵 SMM。预分类器并不需要达到很高的正确识别率。这是因为,一方面,它只需刻画模式间的基本相似性而无须完成最终的识别任务;另一方面,若达到较高的识别性能,通常需要较多数量的样本和较为复杂的算法,这将增加运算的代价。

模式相似性指标用于控制是否启动相似性分析器 A 。若该指标,如 R_A ,超过一定门限,则表明简单的分类器即可达到较高的正确率,故不必建立层次化的分类结构;如果 R_A 不足某个标准,则表明当前的预分类器和样本数据可能尚不足以描述模式之间的相似性,需要对预分类器进行调整或者增加样本数量。在这两种情况下,均不应启动分析器 A 。只有当 R_A 处于特定范围时,才通过触发开关开启分析器 A ,将相似性度量矩阵传递给它。

在相似性分析器 A 中,可以采用多种方法对 SMM 进行处理。由第 1.2.2 节可知,SMM 中的各个元素将不同模式在判决域中所具有的多维分类倾向性之间的关系映射成一维距离量。因此,许多基本的模式识别方法可以直接用来对这个简单的一维物理量进行分析。例如,基于最近邻的方法^[4]根据 lm_{ij} 的不同取值采用基本 k 均值法即可将距离近的类型组合在一起;基于图论的方法^[7]将各个模式类型定义为图中的节点, lm_{ij} 定义为各个节点间

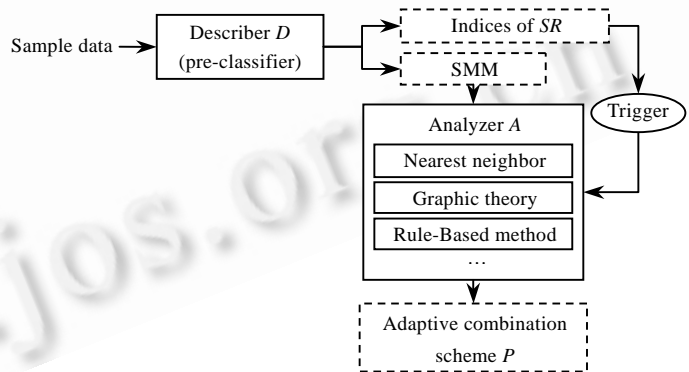


Fig.1 Block diagram of PSRAM

图 1 模式相似关系分析机原理框图

的连接长度,从连接图中获得相应的分割;基于规则的方法^[8]制定若干准则,判断模式之间是否相似,从而形成组合方案 P . 本文以基于规则的分析方法为例进行讨论.

2.3 模式组合规则

首先,按照式(7)对相似性度量矩阵 TM_2 进行归一化处理,得到矩阵 TM_U .

$$tm_{U,ij} = lm_{ij} / t_{max}, \text{ 其中, } t_{max} = \max_{i,j}(lm_{i,j}) \tag{7}$$

然后,设定相似门限 α 和相异门限 β ,这通常由实际样本情况和经验共同决定.

进而,按照如下规则对模式进行自适应重组:

规则 1. 若 $tm_{U,ij} \leq \alpha$,则模式 i 与模式 j 相似,将二者进行组合,记为可组合模式集 $G_m = \{C_i, C_j\}$.

规则 2. 若 $tm_{U,ij} \geq \beta$,则模式 i 与模式 j 相异,不易发生混淆,记为不可组合模式集 $G'_n = \{C_i, C_j\}$.

规则 3. 对于两个可组合模式集 G_{m_1}, G_{m_2} ,若 $G_{m_1} \cap G_{m_2} \neq \emptyset$,则将二者合并.

规则 4. 对于 $\alpha < tm_{U,ij} < \beta$ 的模式 i, j ,由于二者较为相似,需要根据已有可组合模式集 G 和不可组合模式集 G' ,确定它们的“归属”.

规则 4.1. 若 $\alpha < tm_{U,ij} < \beta$,且同时存在一个可组合模式集 $G = \{C_i, C_k\}$ 和一个不可组合模式集 $G' = \{C_j, C_k\}$,则模式 j 不可添加进可组合模式集 G 中.

规则 4.2. 若 $\alpha < tm_{U,ij}, tm_{U,ik} < \beta$,且同时存在可组合模式集 $G_1 = \{C_j, C_k\}, G_2 = \{C_i, C_h\}$,只有当 $tm_{U,hj}, tm_{U,hk}$ 均小于 β 时方可进行组合.

至此,经过 PSRAM 的处理,产生了基于相似性的自适应模式重组聚类方案.根据这种组合关系,可对各个聚类分别设计子分类器,建立起层次化的分类结构.由于子分类器的任务相对简化,计算代价有所降低,故可以采用算法相对复杂但准确性更高的方法,如大规模神经网络^[9]、支撑向量机 SVM^[10]、遗传算法^[5]等.

3 实验分析

3.1 实验数据说明

本文采用从某现役对海警戒雷达上实际测量得到的 8 类舰船目标的视频回波序列作为实验数据.不同类型的舰船目标由于吨位、结构、材质不同,其雷达回波具有一定的规律性^[11,12].但由于受到目标位置、姿态、运动状态、气象及海面状况等多种因素的影响,同一类型目标的雷达回波常表现出较大的差异性,而不同类型目标的回波也可能具有很强的相似性^[12].对于这种复杂的多类目标雷达回波,采用单一结构的分类器很难达到良好的分类性能和稳健的泛化能力,必须采用层次化识别方法,将复杂问题分解为多个简单子问题^[5,11].

通常,这 8 种目标可以按照其吨位不同,划分成大型、中型、小型 3 大类,也可以根据其用途划分成军用、民用两大类,如图 2 所示,其中,基于吨位和用途的组合方案分别用 P_T 和 P_U 代表.不同吨位目标的雷达回波强度、

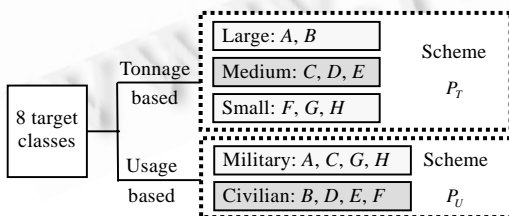


Fig.2 Classes combination schemes with a priori information

图 2 基于先验信息的类型组合方案

稳定性等均有所差别^[11];而不同用途的目标通常在船体结构上具有一定的差异,这将导致其回波具有不同的散射特性^[12].因此,基于上述两种层次化关系构造的分类器能够在一定程度上满足识别需要^[5].然而,在针对雷达回波数据进行目标识别时,基于目标吨位或用途,而不是目标的雷达散射特性来完成层次化聚类,带有较强的主观性和片面性,不够合理.特别是在复杂的实际场景中,模式之间的

相似性可能会发生变化,出现新的模式重组方式,而并非如图 2 所示的固定结构.

表 1 为实验数据清单,其中每个样本都是由基于雷达目标回波数据所提取的 23 维特征矢量^[5,12]构成的.其中,场景 1 和场景 2 为同一部雷达的不同观察区域,训练集/测试集数据分别用于训练/测试分类器,二者互相

独立.

Table 1 Experimental data list

表 1 实验数据清单

Class Data set		A	B	C	D	E	F	G	H	Total
		Scenario 1	Train set 1	552	1 181	424	568	459	298	367
	Test set 1	272	480	154	235	139	78	90	106	1 554
Scenario 2	Train set 2	610	1 724	591	1 227	611	498	342	284	5 887
	Test set 2	150	476	361	527	216	186	102	94	2 112

3.2 实验过程及结果分析

3.2.1 基于场景 1 数据进行的实验

针对训练集 1,首先利用一个双隐层 BP 神经网络^[13]作为相似性分析机中的预分类器 D ,得到混淆矩阵 CM ,见表 2.采用 $L2$ 测度建立相似性度量矩阵,经归一化后得到 TM_U ,见表 3.

Table 2 Confusion matrix CM in scenario 1 ($\times 10^{-3}$)

表 2 场景 1 条件下目标混淆矩阵 $CM (\times 10^{-3})$

	A	B	C	D	E	F	G	H
A	842	127	1087	145	54	0	91	72
B	457	815	500	745	127	0	25	0
C	920	71	833	401	71	71	47	94
D	158	405	370	879	141	106	18	18
E	440	503	126	189	855	0	126	63
F	0	0	0	48	0	986	95	0
G	0	0	0	0	0	0	1000	0
H	385	0	385	769	0	0	0	846

Table 3 The SMM TM_{2U}

表 3 相似性度量矩阵 TM_U

	A	B	C	D	E	F	G	H
A	0	0.811 ⁴	0.746 ¹	0.858	0.838	0.931	0.934	0.834
B	0	0	0.806 ³	0.799 ²	0.816 ⁵	0.918	0.925	0.841
C	0	0	0	0.829 ⁷	0.846	0.922	0.931	0.827 ⁶
D	0	0	0	0	0.861	0.938	0.953	0.834
E	0	0	0	0	0	0.935	0.936	0.860
F	0	0	0	0	0	0	1.000	0.932
G	0	0	0	0	0	0	0	0.940
H	0	0	0	0	0	0	0	0

在相似性分析器中,采用基于规则的方法,经过一定选择和调整^[5],取相似门限 $\alpha = 0.8000$,相异门限 $\beta = 0.8300$.将表 3 中低于 α 的元素以粗体表示,低于 β 的元素所带上标表示其升序排序的序号.

由规则 1,(类型 A,类型 C,0.746),(类型 B,类型 D,0.799)满足相似性的要求,分别记为可组合模式集 $G_1 = \{A, C\}$ 和 $G_2 = \{B, D\}$.

由规则 2,得到不可组合模式集 $\{A, D\}, \{E, G\}$ 等.

不存在能够根据规则 3 合并的可组合模式集.

由规则 4,(类型 B,类型 C,0.806),(类型 A,类型 B,0.811),(类型 B,类型 E,0.816),(类型 C,类型 H,0.827),(类型 C,类型 D,0.829)的相似程度较高,需要进一步确定它们与 G_1, G_2 的关系.

由规则 4.1,类型 H 不可添加进 G_1 ,类型 E 不可添加进 G_2 .由规则 4.2,类型 B 与 A, C 较为相似,但是由于它与类型 D 的相似性最高,而 D 与 A 的相似程度却不满足要求,不可添加进组合 G_1 ;故 G_1 与 G_2 不能进行合并.

至此,由 PSRAM 得到的模式重组聚类方案为 $[G_1, G_2, \text{类型 } E, F, G, H]$.由于 E, F, G, H 相互之间以及它们与 G_1, G_2 之间均存在着较强的差异性,故可将其看作某种模式集组合的不同表现形态,记为 G_3 .进行这样的处理,同时可以达到平衡训练样本数量、提高分类器学习质量的效果.

综上所述,在场景 1 条件下得到的目标自组织聚类方案 $P1$ 将 8 种目标类型归属到 3 个集合,命名为 I 类目标[类型 A,类型 C]、II 类目标[类型 B,类型 D]和 III 类目标[类型 E,类型 F,类型 G,类型 H],如图 3(a)所示.

采用基于吨位、用途和相似关系的聚类方案 P_T, P_U 和 $P1$,利用训练集 1 分别构造 3 个层次化分类器,并使用测试集 1 进行测试.为了便于比较,3 种层次化分类器中的各个子分类器均采用相同结构的 BP 神经网络.为确保实验结果的稳定性和可靠性,我们对在 3 种不同初始条件下训练得到分类器进行测试.表 4 列出了测试的平均正确识别率,并将各个类型在 3 种层次化方案下识别率最高者加粗显示.

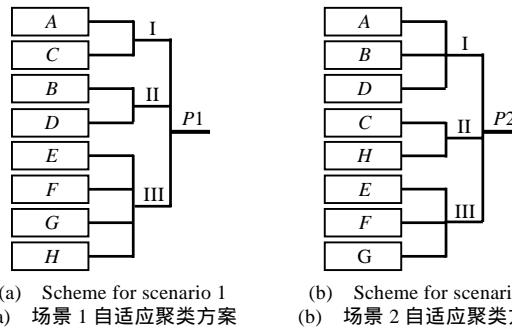


Fig.3 Adaptive combination schemes for various scenarios
图 3 不同场景下目标自适应聚类结果

Table 4 Correct recognition rates by hierarchical classifiers with different schemes in scenario 1
表 4 场景 1 下基于不同组织结构的层次化分类结果

Class	Correct recognition rates (%)		
	Scheme P_T (tonnage)	Scheme P_U (usage)	Scheme P_I (similarity)
A	80	82	90
B	78	81	89
C	82	80	89
D	83	78	91
E	83	86	97
F	98	94	97
G	98	93	99
H	98	90	97

由表 4 可见,基于 P_I 结构的层次化分类器,除了对类型 F 和 H 的最终识别率略低于方案 P_T 以外,对其余 6 种类型的正确识别率较之其他两种方案均有较大幅度的提高,有的甚至超过 10%,如类型 A, B, E 等.同时,与表 2 中的对角线元素相比可知,基于吨位及用途的层次化分类器与单一型分类器相比,识别性能不仅没有改善,反而表现出一定程度的下降;而基于相似性的自适应层次化分类器则表现出较为稳定和较大幅度的提高.这说明,不合理的层次化分类结构可能会导致识别性能的下降.上述结果不仅说明了合理设计层次化分类器结构的重要性,同时也证实了本文所提出方法的有效性和稳健性.

3.2.2 基于场景 2 进行的实验

针对训练数据集 2,首先按照相同的方法获取基于相似性的层次化分类方案 P_2 ,如图 3(b)所示;然后分别根据 P_T, P_U 以及方案 P_2 训练层次化分类器,每层中的各个子分类器仍然采用具有相同结构的 BP 神经网络,在不同初始条件下训练 3 次,分别对测试数据集 2 进行测试,平均正确识别率见表 5.

Table 5 Correct recognition rates by hierarchical classifiers with different schemes in scenario 2
表 5 场景 2 下基于不同组织结构的层次化分类结果

Class	Correct recognition rates (%)		
	Scheme P_T (tonnage)	Scheme P_U (usage)	Scheme P_2 (similarity) (%)
A	80	81	87
B	82	76	80
C	81	80	83
D	80	76	95
E	81	82	97
F	97	85	98
G	96	87	98
H	96	87	98

由图 3 和表 5 可以看到:(1) 场景 2 中基于目标相似性产生的自组织聚类方案 P_2 与场景 1 下的方案 P_I 有较大差别,可见,始终使用同一种层次化结构处理多种复杂场景是不够合理的;(2) 基于方案 P_2 得到的层次化分类器,综合识别率仍远高于基于吨位和用途所设计的分类器,表现出稳定的优越性,更进一步地验证了本文的

方法的可行性和有效性;(3) 通过本组实验再次说明了层次化分类器的综合性能是由各层子分类器的组织结构及实际效能共同决定的,必须对其进行合理设计.

4 结束语

通过本文的理论分析和综合测试,可以得到以下结论:

1. 层次化分类器的合理设计意义重大,基于模式间相似性自适应地构造分类器组织关系,能够增加模式重新聚类后的类内一致性和类间可分性,从而提高分类器构造效率,降低维护系统的难度.

2. 本文的方法以各类目标在特征空间与识别空间中的表现形态为切入点,采用简便、可行的手段获取关于目标相似性与差异性的度量指标,从而实现满足 Fisher 准则的层次化聚类方案.其识别正确率、可靠性和泛化能力均优于常规的层次化方法.

3. 针对实际应用中复杂场景下的目标识别问题,聚合各模式类型时不能在所有场合中都仅采用一种固定形式,应根据具体情况进行相应的调整.

最后,指出使用本文的方法时需要注意的问题:

1. 在 PSRAM 中,若模式间相似性不强,即相似程度描述器 D 得到的模式相似性综合指标在允许范围之内,则无须进行层次化分类,以避免分类器结构复杂化所带来的负面影响.若分析器 A 提示无法有效地进行自适应聚类重组,则需要根据其他知识确定层次关系的组织结构.

2. 为了准确、可靠地获取不同模式之间的相似性,在相似程度描述器 D 和相似性分析器中,可以采用不同的方法进行多次实验,以确保获取模式间相似性的有效度量,从而建立稳定的层次化组织结构.

References:

- [1] Ruda H, Snorrason M, Shue D. Framework for automatic target recognition optimization. No.R96451, Cambridge: Charles River Analytics, 1997.
- [2] Jain AK, Duin RPW, Mao JC. Statistical pattern recognition: A review. 1999. <http://citeseer.ist.psu.edu/jain99statistical.html>
- [3] Song R, Ji H, Xia SP, Hu WD, Yu WX. Hierarchical modular structure for automatic target recognition systems. In: Shen J, Pankanti S, Wang RS, eds. Proc. of the SPIE, Vol 4554, Object Detection, Classification and Tracking Technologies. Bellingham: SPIE, 2001. 57-61.
- [4] Sun JX, et al. Modern Pattern Recognition. Changsha: National University of Defense Technology Press, 2002 (in Chinese).
- [5] Zhang J. Research and implementation of flexible radar target recognition [Ph.D. Thesis]. Changsha: National University of Defense Technology, 2004 (in Chinese with English abstract).
- [6] Logan JD. Applied Mathematics. 2nd ed., Hoboken: Wiley-Interscience, 1996.
- [7] Rosen KH. Discrete Mathematics and Its Applications. 5th ed., Berkshire: McGraw-Hill Science/Engineering/Math, 2003.
- [8] Chen WW. Intelligent Decision Making. Beijing: Publishing House of Electronics Industry, 1998 (in Chinese).
- [9] Ripley BD. Pattern Recognition and Neural Networks. London: Cambridge University Press, 1996.
- [10] Vapnik VN. The Nature of Statistical Learning Theory. New York: Springer-Verlag, 1995.
- [11] Yu WX. Intelligent recognition approaches and their applications in the radar ship target recognition system [Ph.D. Thesis]. Changsha: National University of Defense Technology, 1992 (in Chinese).
- [12] Zhang J, Song R, Yu WX, Xia SP, Hu WD. Visual effects based feature extraction for dynamic radar target echo series. In: Yuan BZ, et al., eds. Proc. of the 7th Int'l Conf. on Signal Processing (ICSP 2004). Beijing: Publishing House of Electronics Industry, 2004. 2111-2115.
- [13] Song R, Zhang J, Xia SP, Yu WX. An adaptive classification method of bp-nn group based classification system and its application. ACTA Electronica Sinica, 2001,29(12A):1950-1953 (in Chinese with English abstract).

附中文参考文献:

- [4] 孙即祥,等.现代模式识别.长沙:国防科技大学出版社,2002.
- [5] 张静.柔性雷达目标识别技术研究及实现[博士学位论文].长沙:国防科学技术大学,2004.
- [8] 陈文伟.智能决策技术.北京:电子工业出版社,1998.
- [11] 郁文贤.智能化识别方法及其在舰船雷达目标识别系统中的应用[博士学位论文].长沙:国防科技大学,1992.
- [13] 宋锐,张静,夏胜平,郁文贤.一种基于 BP 神经网络群的自适应分类方法及其应用.电子学报,2001,29(12A):1950-1953.