

水下目标识别的特征融合分类器设计

侯平魁¹, 史习智¹, 林良骥², 王学军³

(1. 上海交通大学振动、冲击、噪声国家重点实验室, 上海 200030; 2. 大连测控技术研究所, 大连 116013; 3. 上海大众汽车有限公司, 上海 201805)

摘要: 本文对水下目标识别中的特征融合技术进行了研究, 讨论了特征融合技术中的问题和解决途径, 并给出了特征融合分类器的特性; 设计了模糊融合分类器, 给出了具体的算法. 该分类器对样本在模式空间中的分布不做任何假定, 注重类别间的相互约束, 强调各个模式的独立作用, 用类似于模糊并运算的方式综合这些作用. 在实际应用中, 通过与已有的分类器比较, 表明模糊融合分类器能够综合多种信号特征, 有效地提高了分类性能.

关键词: 特征融合; 目标识别; 水下目标; 分类器

中图分类号: TN911 **文献标识码:** A **文章编号:** 0372-2112 (2001) 04-0443-04

Design of Feature Fusion Classifier for Underwater Targets Recognition

HOU Ping-kui¹, SHI Xi-zhi¹, LIN Liang-ji², WANG Xue-jun³

(1. State Key Lab. of Vibration, Shock & Noise, Shanghai Jiaotong University, Shanghai 200030, China;

2. Dalian Test & Control Technology Institute, Dalian 116013, China;

3. Shanghai Volkswagen Automotive Company Ltd., Shanghai 201805, China)

Abstract: This paper discusses feature fusion technique in underwater target recognition and proposes the method dealing with the problem encountered. Then, fuzzy fusion classifier (FFC) was designed based on this concept. FFC does not make any assumption about samples' distribution in pattern space, but emphasizes mutual restraints among classes and the independent role of each pattern and synthesizes those role by operation like combination in fuzzy logic. In practice, FFC can efficiently improve classification performance of recognition system by synthesizing features from multisensors.

Key words: feature fusion; target recognition; underwater target; classifier

1 引言

信息融合 (Information Fusion, IF) 技术出现在 70 年代末期, 早期研究主要是基于应用背景. 随着研究的深入和应用领域的扩大, 信息融合技术已成功地应用于军事和民用领域的诸多方面. 信息融合是与多传感器系统相适应的横向信息综合处理技术, 其任务是把各个传感器在空间或时间上冗余或互补的数据, 依据某种准则进行组合, 以获得对被测对象的一致性描述或理解, 使该系统比组成它的各个子系统具有更优越的性能^[1]. R. Mason^[2,3]将传感器拓展为广义传感器—真实的传感器或声纳在不同时段、频段或处理机制下获取的信号, 从概念上确立了数据融合在水下目标识别中的地位, 为应用数据融合解决水下目标识别的实际课题铺平了道路.

Frances B. Shin 等人^[4]指出, 特定的变换算法通过原始信号到特定空间的投影可以实现对某些干扰的压制和分离, 综合利用多个变换算法就能更为准确和简单地描述期望信号. 变换算法的这种子空间滤波 (Subspace Filtering) 和能量压缩 (Energy Compaction) 特性是广义传感器存在的基础.

本文针对水下目标识别, 研究了广义传感器条件下的特

征融合技术. 这种特征融合实质上是在特征层次上的联合模式识别, 其方法也是采用模式识别的相应技术^[5]. 然而, 在这种条件下, 模式识别的复杂性大大增加了, 这就需要一些新的技术和观点.

2 特征融合分类器

2.1 特征融合技术中的问题及解决途径

在设计特征融合分类器时, 应当采用模式识别的相应技术. Frances B. Shin 等人从七个广义传感器中选择了一千五百多个特征, 在特征优化的基础上比较了几种分类器的性能. 他们的工作表明, 特征融合技术的确可以有效地改善识别性能, 然而其技术却相当复杂. 这种复杂性主要表现在特征优化上. 一方面, 特征优化的效果对分类器性能影响较大, 必须获取少数有效的独立特征, 冗余特征的存在将降低分类器性能. 另一方面, 为了有效地压制干扰, 必须选用多个广义传感器, 这给特征优化提出了很高的要求. 特征优化主要分为两个部分. 一是通过线性或非线性映射缩减维数, 获取具有较好的类内紧致性和类间可分性的线性独立特征. 二是特征选择, 包括一维和多维选择. 一维特征选择并不困难, 但是却无法处理特征的

相关性,导致低劣的分类性能.其原因有三方面,一是在特征融合中不可避免地出现大量相关特征,二是现有的分类器在设计时往往不考虑特征的相关性,三是受样本容量的限制只能选用有限的特征.本文的目的就是寻找适当的途径缓解这一矛盾.

推本溯源,样本容量的限制是无法改变的,问题的核心就是分类器,必须设计与特征融合技术相适应的新型分类器,即特征融合分类器.与现有的分类器不同,特征融合分类器在设计时就考虑特征的相关性,力图避免相关特征的不利影响,包括相关特征的增加不受样本容量的限制和不降低分类性能等.特征融合分类器可以充分利用互补特征,避免特征优化的复杂性,充分发挥特征融合技术的优势.此外,特征融合分类器还简化了特征融合技术.

2.2 特征融合分类器的应有的特性

在设计特征融合分类器时,必须考虑它的特性.我们认为,特征融合分类器应当具有以下特性.

首先,特征融合分类器首选是神经网络分类器.神经网络既是表现智能的机制,也是实现机器学习的最重要的技术手段之一.为了保证识别系统的灵活性和适应性,使用神经网络分类器是必然的选择.

其次,特征融合分类器必须是性能优良的分类器,包括可以形成复杂的非线性判决界,学习速度快,需要人工调整的参数少等. Patrick K. Simpson^[9]系统地讨论了这些特性,并在此基础上提出了模糊最小——最大神经网络分类器(Fuzzy Min-Max Neural Networks, FMMNN).

再次,特征融合分类器应当具有较强的通用性,允许 n 维模式空间 P^n 是 R^n 或其任意的子空间,方便广义传感器的构造;同时提供软判决(Soft Decision)和硬判决(Hard Decision),方便决策融合的实现.

最后,特征融合分类器应当尽可能避免相关特征的不利影响,方便特征融合技术的实现,充分发挥其优势.这是特征融合分类器最重要的特性,它决定了特征融合分类器在实现上的几个特点:对样本在模式空间中的分布不做任何假定;强调各个模式的独立作用,作用的综合类似于模糊集合的并运算;强调类别间的相互约束.

3 模糊融合分类器的实现

模糊融合分类器的基础是超箱.正象三维正交坐标系中的长方体可以用它的一对顶点来描述一样, P^n 中的超箱可以用它的最小模式和最大模式来表示.任一样本对超箱的偏离由偏离函数计算.偏离函数对各个模式的独立作用进行综合,以超箱在各个模式上的长度作为比较的基准,因为这些长度的相对大小反映了判决界的局部弯曲程度.规定超箱在各个模式上的长度始终不是零.一个类别包含一组超箱.任一样本对一个类别的偏离是分别对超箱的偏离的最小值.不同类别的超箱不重叠或邻接,即相互排斥.这样, P^n 中的一个类别就可以表示为以一组超箱为基础构造的模糊集合.任一样本对某类别的隶属度与类别间的相互约束有关,取决于它对该类别的偏离和平均偏离的相对大小,由隶属度函数计算.

3.1 基本概念

设在 P^n 中共有 K 个类别,当前共有 J 个超箱.定义符号:

$$H_j \{ C_j, A_j, B_j \}, (j = \{1, 2, \dots, J\}) \quad (1)$$

表示超箱 H_j . 该超箱属于类别

$C_j (C_j = \{1, 2, \dots, K\})$, 最小模式是 A_j , 最大模式是 B_j .

在分类过程中,设当前样本的模式是 X , 它对超箱 H_j 的偏离函数为:

$$f_d(X, H_j) = \max_{i=1,2,\dots,n} \{ [\max(A_j^{(i)} - X^{(i)}, 0) + \max(X^{(i)} - B_j^{(i)}, 0)] / (B_j^{(i)} - A_j^{(i)}) \} \quad (2)$$

X 对类别 $k (k = \{1, 2, \dots, K\})$ 的偏离是:

$$d_k = \min_{C_j=k} \{ d_j \} \quad (3)$$

$$\bar{d} = \frac{1}{K} \cdot \sum_{k=1}^K d_k \quad (4)$$

是 X 对各类别的平均偏离; X 对类别 k 的隶属度 m_k 由隶属度函数:

$$f_m(d_k, \bar{d}) = e^{-d_k^2 / \bar{d}^2} \quad (5)$$

给出.在学习过程中,设超箱 $H = \{ C, A, B \}$ 属于类别 $k (C = k)$, 如果对不属于 k , 模式为 X 的样本, 不等式:

$$A^{(i)} > X^{(i)} \quad (6)$$

或 $B^{(i)} < X^{(i)}, i = \{1, 2, \dots, n\}$

至少成立一个,我们说 H 对样本 X 满足排斥条件:

如果对其它类别的任意超箱:

$$H_j = \{ C_j, A_j, B_j \} (C_j \neq k) \quad (7)$$

不等式:

$$A^{(i)} > B_j^{(i)} \quad (8)$$

或 $B^{(i)} < A_j^{(i)}, i = \{1, 2, \dots, n\}$

总是至少一个成立,我们说 H 对超箱满足排斥条件.在学习过程中使用如下的迭代公式:设超箱

$$H = \{ C, A_r, B_r \} (r \geq 0, r = Z) \quad (9)$$

的参考模式为 D , 初值是 A_0 和 B_0 , 则

$$A_r = (D + 2A_{r-1}) / 3 \quad (10)$$

$$B_r = (D + 2B_{r-1}) / 3$$

循环结束条件是 H 满足某种排斥条件.

3.2 分类算法的主要步骤

用 X 表示待分类样本的模式,分类算法的步骤如下:

(1) 根据式(2)计算 X 对各个超箱的偏离

$$d_j = f_d(X, H_j), j = 1, 2, \dots, J;$$

(2) 根据式(3)计算 X 对各个类别的偏离

$$d_k, k = 1, 2, \dots, K;$$

(3) 根据式(4)计算 X 对各个类别的平均偏离 \bar{d} ;

(4) 根据式(5)计算 X 对各个类别的隶属度

$$m_k = f_m(d_k, \bar{d}), k = 1, 2, \dots, K$$

隶属度 (m_1, m_2, \dots, m_K) 就是模糊融合分类器对 X 作出的软判决.如有必要,我们可以根据合理的规则从这个软判决得出硬判决.在本文中,选用下面的规则:

if $\exists l \in \{1, 2, \dots, K\} : m_l > \max_k \{m_k\}$
 then $X \in l$

3.3 学习算法的主要步骤

设当前的学习样本属于类别 k , 其模式是 X , 学习算法的步骤如下:

(1) 压缩其它类别的超箱

设 $H_j = \{C, A_r, B_r\}$, $C = C_j$, 取参考模式

$$D^{(i)} = \begin{cases} A_j^{(i)} X^{(i)} - A_j^{(i)} > B_j^{(i)} - X^{(i)} \\ B_j^{(i)}, \text{ otherwise} \end{cases} \quad (11)$$

初值 $A_0 = A_j$ 和 $B_0 = B_j$, 迭代计算 A_r 和 B_r 至 H 对样本 X 满足排斥条件, 然后, 更新 H_j , 令 $H_j = H$;

(2) 扩展类别 k 的超箱

对于类别 k 中的超箱, 设 X 对 $H_{j1} = \{C_{j1}, A_{j1}, B_{j1}\}$ 的偏离最小, 即满足 $j_1 = \arg \min_{j \in k} \{b_j\}$, 构造超箱

$$H = \{C_r, A_r, B_r\}, C = k \quad (12)$$

取参考模式 $D = X$, 初值为:

$$A_0^{(i)} = \min \{X^{(i)}, A_{j1}^{(i)}\} \quad (13)$$

$$B_0^{(i)} = \max \{X^{(i)}, B_{j1}^{(i)}\} \quad (14)$$




图 1 模糊融合分类器的结构 图 2 输出结点 M_k 的结构

迭代计算 A_r 和 B_r 至 H 对超箱满足排斥条件, 如果 $r=0$, 即

$$H = \{k, A_0, B_0\} \quad (15)$$

则更新 H_{j1} , 即令 $H_{j1} = H$; 否则 H_{j1} 不变, 添加属于类别 k 的新超箱 $H_{j+1} = H$, 特别地, 如果类别 k 当前尚不包含任何超箱, 则令初值

$$A_0 = X^- \text{ 和 } B_0 = X^+$$

添加属于类别 k 的新超箱 $H_{j+1} = H$. 通常 (i) 可取为 P^i 在第 i 维上长度的百分之一.

每次学习前对当前样本集随机排序, 反复学习至不再添加新的超箱. 通常对一个样本集只需学习几次, 并且 FFC 没有任何需要人工调整的参数, 因此它的学习速度相当快.

在学习算法中, 有时可以采用附加的手段来提高学习效率, 改善学习效果. 在最初的学习阶段, 超箱对各个类别的描述还不够清晰, 可以考虑用样本暂时弥补: 建立一个样本子集, 将步骤 (2) 中的“对超箱满足排斥条件”改为“对超箱和子集中的样本满足排斥条件”; 如果样本集较大, 许多超箱都发生了变化, 学习结束后可以考虑合并同类超箱: 对于类别 k 的任意两个超箱

$$H_{j1} = \{C_{j1}, A_{j1}, B_{j1}\}$$

$$H_{j2} = \{C_{j2}, A_{j2}, B_{j2}\} (C_{j1} = C_{j2} = k),$$

构造超箱

$$H = \{C, A, B\}, C = k,$$

$$A^{(i)} = \min \{A_{j1}^{(i)}, A_{j2}^{(i)}\},$$

$$B^{(i)} = \max \{B_{j1}^{(i)}, B_{j2}^{(i)}\};$$

如果 H 对超箱满足排斥条件, 则接受该合并, 令 $H_{j1} = H$, 丢弃 H_{j2} . 如图 1 至图 4 所示, 模糊融合分类器是有两个隐层的前向神经网络, 具有良好的分布计算特性.




图 3 隐层结点 H_j 的结构

图 4 隐层结点 D_k 的结构

4 实验与讨论

通过长期的分类实验研究, 我们发现实验信号中含有丰富的目标分类信息. 本文在以前工作的基础上提取了波形结构特征: 过零点特性、峰间幅值分布特性、波长差特性和波列面积特性共 13 维特征提取. 另外, 本文也提取了目标信号的 Burg-Cepstrum 谱特征共 30 维作为网络的输入. 在此基础上, 我们又设计了平滑能量扫描特征提取算法, 提取出 28 维特征. 实验中将三类特征共 71 维进行规范化, 再采用 Karhunen-Loeve 变换 (期望平均误差为 0.02) 进行特征抽取, 得到 47 维有效特征作为分类器的输入模式. 实验中基于原始特征 (71 维) 有效特征 (47 维) 对模糊自适应分类器和模糊融合分类器进行比较, 并用实验验证了模糊融合分类器的有效性. 实验样本数为 705 个, 分别来自真目标、假目标和混响, 均为海上实测的回波信号, 学习集与测试集的样本数之比为 1:2, 对测试集的分类结果见表 1.

表 1 模糊自适应分类器和模糊融合分类器的比较

	模糊自适应分类器		模糊融合分类器	
输入特征	71 维特征	47 维特征	71 维特征	47 维特征
正确识别率	75.1 %	85.5 %	91.5 %	92.6 %

从实验结果可以看出, 模糊自适应分类器没有融合特性, 采用 Karhunen-Loeve 变换进行特征抽取可以有效地提高其分类性能, 而潜在的相关特征制约了性能的进一步改善. 与此相反, 模糊融合分类器具有融合特性, 可以自动过滤冗余特征的负面影响, 其性能不因冗余特征的存在而降低; 采用 Karhunen-Loeve 变换进行特征抽取, 对模糊融合分类器的分类性能影响不大, 这时分类性能略微改善的原因可能有二, 一是特征的类内紧致性和类间可分性提高了, 二是学习样本不足带来的损失减小了.

5 结论

本文对目标识别中的特征融合技术进行了研究, 提出了特征融合分类器的概念, 为特征融合技术的实用化铺平了道路. 从这一概念出发, 以相关的理论和实验为基础, 设计了模

模糊融合分类器,给出了具体的算法.在实际应用中,模糊融合分类器综合多种信号特征,有效地提高了分类性能,解决了声纳目标识别领域当前面临的主要技术难点之一,为特征融合技术的深入开展开辟了一条新的技术途径.

参考文献:

- [1] 吴新垣. 信息融合及其智能化途径探讨 [J]. 舰船科学技术, 1996(3):42 - 46;1996(5):49 - 52.
- [2] R. Mason. Data fusion for detecting sonar contacts from multiple sensors: the two sensor case [A]. OCEANS '93 [C], 1993, (): 214 - 219.
- [3] R. Mason. Data fusion for detecting sonar contacts from multiple sensors [A]. OCEANS '94 [C], 1994(): 562 - 567.
- [4] F. B. Shin, D. H. Kil and R. F. Wayland. Active impulsive echo discrimination in shallow water by mapping target physics-derived features to classifiers [J]. IEEE Journal of Oceanic Engineering 1997, 22(1): 66 - 80.
- [5] R. C. Luo and M. G. Kay. Multisensor Integration and Fusion for Intelligent Machines and Systems [M]. Ablex Publishing Corporation, 1995.
- [6] Y. Pao. Dimension Reduction, feature extraction and interpretation of data with network computing [J]. International Journal of Pattern Recognition and Artificial Intelligence, 1996, 10(5): 521 - 535.
- [7] M. Prakash and M. N. Murty. Growing subspace pattern recognition methods and their neural-network models [J]. IEEE Transactions on Neural Networks, 1997, 8(1): 161 - 168.

- [8] Q. Li and D. W. Tufts. Principal feature classification [J]. IEEE Transactions on Neural Networks, 1997, 8(1): 155 - 160.
- [9] P. K. Simpson. Fuzzy min-max neural networks—Part 1: classification [J]. IEEE Transactions on Neural Networks, 1992, 3(5): 776 - 786.

作者简介:



侯平魁 1975年4月出生,于1996年毕业于上海交通大学动力与能源工程学院,现为上海交通大学振动、冲击与噪声国家重点实验室博士生,主要研究方向:目标识别、数据融合、混沌、神经网络.



史习智 上海交通大学振动、冲击与噪声国家重点实验室教授,博士生导师,当前的研究兴趣包括:信号处理与软计算、感知器的计算理论、信息融合、数据挖掘与智能控制.