

强混叠模式下基于神经元捕获/抑制原理的分类器设计

张军英^{1,2}, 梁军利¹, 保 铮²

(1. 西安电子科技大学计算机学院, 陕西西安 710071; 2. 西安电子科技大学雷达信号处理国家重点实验室, 陕西西安 710071)

摘 要: 目前的许多分类器设计方法,如多层感知器网络(MLP)、支持向量机(SVM)、相关向量机(RVM)、径向基函数网络(RBF)等,实际是非线性映射加线性分类的方法,即将输入空间的非线性可分问题经非线性映射到另一空间,在那一空间实现线性分类.本文则开拓性的运用脉冲耦合神经网络神经元的点火捕获的思想,提出了一种基于耦合神经元点火捕获/抑制特性的分类器设计方法,使一类样本对应神经元总是较其它类样本对应神经元先点火以实现对本类样本的有效分类.所设计的分类器可实现对样本空间中任意复杂分布训练样本的非线性稳健分类,特别是有效实现复杂混叠模式的模式稳健分类,大量复杂混叠模式分类问题的仿真实验验证了本文方法的有效性和可行性,并应用于微波暗室实测一维距离像数据的自动目标识别中.

关键词: 脉冲耦合神经网络(PCNN); 神经元点火的捕获和抑制; 稳健分类器

中图分类号: TP391 文献标识码: A 文章编号: 0372-2112(2006)12-2154-07

Classifier Design for Heavy-Overlap Patterns Based on Capture/Inhibition Principle

ZHANG Jun ying^{1,2}, LIANG Jun li¹, BAO Zheng²

(1. School of Computer Science and Engineering, Xidian University, Xi'an, Shaanxi 710071, China;

2. Electronics Engineering Institute, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Nonlinear mapping plus linear classification, i. e., mapping inseparable input space into a hidden space via some nonlinear mapping, and designing a linear classifier to classify the data in the hidden space, is one of the most popular approaches for designing a classifier for an inseparable classification problem. In fact, multi-layer perceptron (MLP), support vector machine (SVM), relevance vector machine (RVM) and radial basis function (RBF) are the examples of such approach. In this paper, we propose a novel classifier which is not based on this approach, but on stimulating pulse coupled neurons such that the neurons belonging to a same class activate each other while those belonging to different classes inhibit each other according to the stimulus and the geometry of neurons in the input space. The result of the competition between neurons is that all the neurons belonging to one class will fire earlier than all the other neurons in the net, which is used for classification. A large number of experiments were conducted for classification of Iris data and simulated data where the overlap between patterns is very serious, as well as automatic target recognition for the model targets whose high resolution range profiles were obtained from real microwave house. The experiments show that the proposed method is very effective in designing a classifier with good generalization ability and simple structure.

Key words: pulse coupled neural network(PCNN); capture and inhibition between the fires of neurons; robust classification

1 引言

模式的分类、识别和集群等,已在诸如生物学、生理学、药理学、计算机视觉、人工智能、图像处理 and 识别等各种工程和科学领域成为越来越重要的问题^[1].基于数据统计信息的 Bayes

准则^[1,2]由于统计信息获取困难而极大限制了其广泛应用.基于数据驱动的分类器,如多层感知器网络(MLP, Multi Layer Perceptron)^[1,3-5]、径向基函数网络(RBF, Radial Basis Function Network)^[6]、支持向量机(SVM, Support Vector Machine)^[7,8]和相关向量机(RVM, Relevance Vector Machine)^[9]等,尽管有在网

规模、学习速度、推广能力等方面的各自优势,但它们有一个共同特点,即将输入空间的非线性可分问题经非线性映射到另一空间,在那一空间实现线性分类。如 MLP 将输入空间的非线性可分问题通过多层(单层为其特例)的非线性变换,映射到一个线性可分空间,并用输出神经元实现分类;而 RBF/SVM/RVM 类分类器,则是通过高斯核/Mercy 核/核函数/将输入空间的非线性可分问题映射到足够高维的某个空间上,并用输出神经元实现线性分类,所需的核函数数目则分别对应了径向基函数数/支持向量数/相关向量数,并表示了分类器的结构复杂性。

脉冲耦合神经网络(Pulse Coupled Neural Network—PCNN)是 Eckhorn 提出的一种解释猫大范围的大脑皮层中实验观察到的与特征有关同步行为的一个简化模型^[11],这种模型作为一种新型的图像处理工具,具有以空间邻近和亮度相似集群的特点,已在图像分割^[12]、图像融合^[13]、图像凹点检索^[14]、图像目标检测^[15]、最短路求解^[15]、图像特征提取^[18]、图像滤波^[19]、最短路问题求解^[17]等问题中有广泛的应用研究,IEEE Trans on Neural Networks 在 1999 年 5 月就专门出版了脉冲耦合神经网络专刊,文献[22]也通过 PCNN 获得图像的时间索引图并将其作为 MLP 的输入由 MLP 最终实现图像分类,目前多数的研究^[13, 16, 18, 22]仍属于用 PCNN 进行特征提取用线性分类器设计方法进行分类器设计的范畴,至今没有关于运用脉冲耦合神经网络的工作机理进行模式分类和识别方面研究的报道。本文开拓性地将 PCNN 基于空间邻近和亮度相似的神经元点火捕获特性运用于二分类问题的分类器设计。这种分类器设计方法通过运用 PCNN 神经元点火的捕获特性,并引入神经元点火的抑制机制,可实现任意复杂分布训练样本(且没有矛盾样本)多类问题的最稳健非线性分类。该方法既运用类内样本统计分布信息,通过类内样本捕获点火和类间样本抑制点火,从而使某类样本总是先于另一类样本点火,进而实现样本的分类。该方法既与 Bayes 方法仅基于类内样本统计分布信息不同,又与 RBF/SVM/RVM 方法基于非线性映射和线性分类不同,是一种崭新的模式分类方法。其特点是:(1)所设计的分类器结构简单,却可实现任意复杂分布训练样本二分类问题的最稳健分类,甚至可以达到对训练样本的错误识别率总为 0,且分类器的推广能力最强(即边界最大);(2)分类器的设计仅需一个参数(网络捕获强度)的计算,无须迭代训练从而没有局部极小点问题;(3)无论是分类器设计和测试样本的类别预测,都无须运行一个脉冲耦合神经网络。实际上我们只是运用脉冲耦合神经网络神经元的捕获/抑制思想提出分类器设计方法,而没有真正运行网络。大量仿真实验和雷达一维距离象数据的分类结果验证了这一方法的有效性和可行性。

2 PCNN 的模型和运行行为分析

PCNN 是由若干个 PCNN 的神经元互连所构成的反馈型网络,其每一神经元由三个部分组成:分支树、链接器和脉冲产生器,如图 1 所示。在图 1 中 Y_k , U_k 为神经元 k 的输出和内部行为,分支树中有两个分支,以形成馈送输入 F_k 和链接输

入 L_k , 其中 F_k/L_k 分别是以相对较小/较大的时间常数 τ_{F_k}/τ_{L_k} 对神经元 k 的馈送邻域/链接邻域内的其它神经元输出进行漏电容积分的加权之和的结果,此外 F_k 还接受该神经元的外部刺激 S_k ; 链接器以乘积耦合 $U_k = F_k(1 + \beta L_k)$




图 1 脉冲耦合神经元的神经元模型

构成神经元 k 的内部行为 U_k ; 脉冲产生器由对网络输出进行漏电容积分的变阈值特性(起激活该神经元的作用)和硬限幅函数(起抑制该神经元的作用)组成,从而在神经元输出产生脉冲信号。PCNN 的神经元 i 的离散方程形式为:

$$\begin{aligned}
 F_i(n) &= e^{-\Delta t/\tau_{F_i}} F_i(n-1) + V_F \sum_j M_{ij} Y_j(n-1) + S_i \\
 L_i(n) &= e^{-\Delta t/\tau_{L_i}} L_i(n-1) + V_L \sum_j W_{ij} Y_j(n-1) \\
 U_i(n) &= F_i(n) (1 + \beta L_i(n)) \\
 \theta_i(n) &= e^{-\Delta t/\tau_{\theta_i}} \theta_i(n-1) + V_{\theta_i} Y_i(n) \\
 Y_i(n) &= \begin{cases} 1, & U_i(n) \geq \theta_i(n) \\ 0, & U_i(n) < \theta_i(n) \end{cases} \quad (1)
 \end{aligned}$$

其中 M_{ij} 和 W_{ij} 为神经元 i 的馈送域和链接域中神经元 j 与神经元 i 的连接权。馈送参数 V_F , τ_{F_i} , M_{ij} , 链接参数 V_L , τ_{L_i} , W_{ij} 和阈值参数 V_{θ_i} , τ_{θ_i} 以及捕获强度参数 β 均在网络运行前给定。

文献[1]认为由图 1 神经元所构成的网络,(1)由于存在大量非线性和漏电容积分等因素,使得对网络的数学分析困难;(2)基于空间邻近和亮度相似的象素集群模糊;(3)网络参数难于确定。进而将图 1 的神经元简化,其中 F_i 只接受外部刺激信号 S_i ; 若神经元 k 在 t_1 和 t_2 两个时刻点火,则该神经元的变阈值形式为

$$\theta_k = \begin{cases} V_{\theta_0}, & t = t_1 \\ V_{\theta_0} \exp(-\tau_{\theta_0}(t - t_1)), & t_1 < t < t_2 \\ V_{\theta_0}, & t = t_2 \end{cases} \quad (2)$$

PCNN 通常用于图像分割^[12]和图像处理^[13-15, 18, 19],在用 PCNN 进行图像处理时,通常网络与图像一样大,即网络的神经元数目与图像象素数目相同;象素 (i, j) 的强度 $x_{i,j}$ 即作为神经元 (i, j) 的外部输入,即 $F_{i,j}(t) = x_{i,j}$ 。脉冲耦合神经网络的基本特性是神经元点火所引起的点火神经元邻域的神经元的捕获点火特性,即若某神经元受到外部刺激而发生点火(兴奋),该神经元的点火会带动(捕获)其邻域满足一定条件的神经元也点火(兴奋),从而具有将位置邻近亮度相似的象素集群的特点。下面给出我们运用这种捕获点火机制实现模式分类的基本思想和方法。

3 基于神经元捕获/抑制特性的模式分类

3.1 基本思想

设特征空间中具有 K 类样本,第 k 类中的第 i 个样本记为 X_{ki} , 现要设计分类器,将特征空间中的训练样本分类开来,并具有最大推广能力,为此,我们设计一个 PCNN,其每一神经

元对应一个样本. 为表述方便, 我们常常将神经元与样本不加区分.

我们认为 PCNN 神经元的点火捕获机制可以很好地实现具有最大推广能力的稳健分类器的设计. 对于两类问题即 $K=2$ 的情况, 记样本的类属信息为 $y \in \{-1, 1\}$, 如果设计 PCNN, 以每类中的任一样本在样本空间中的分布密度作为对应神经元的外部刺激, 通过网络链接的设计实现神经元的捕获点火和抑制点火, 从而使某类样本(如属于 C_1 的样本)对应神经元的点火能够捕获与其类属相同的所有样本对应的神经元的点火, 同时能够抑制与其类属不同(如属于 C_2)的所有样本对应神经元的点火, 从而在一个点火周期内, 该类样本对应神经元均在某时刻以前点火, 而另一类样本对应神经元均在这一时刻以后点火, 实现对训练样本的分类, 并通过这个时间阈值实现对测试样本的分类: 若其对应神经元在此阈值之前点火, 则属于 C_1 类, 否则属于 C_2 类. 当将这个时间阈值放在 C_1 类样本最晚点火时刻和 C_2 类样本最早点火时刻的中间(称这个阈值为时间中值阈值), 则实现的将是具有最大推广能力的稳健分类器.

3.2 PCNN 参数的设计

3.2.1 神经元的外部刺激

若 x_{ki} 表示 $C_k (k=1, 2)$ 中第 i 个样本 X_{ki} 的外部刺激, 为其基本描述 C_k 上的样本在 X_{ki} 点的分布密度, 即与其距离越近/越远的 C_k 上的样本对其的贡献越大/越小, 并用 $d_{ki, lj}$ 表示 X_{ki} 与 X_{lj} 的欧氏距离, 则可取

$$x_{ki} = \sum_{j \neq i} \frac{1}{d_{ki, lj}^2} \quad (3)$$

相对于 PCNN 进行图像处理, 这里样本 X_{ki} 的外部刺激 x_{ki} 相当于图像像素 (k, i) 的亮度. 为此, 以下也常将神经元的外部刺激与样本的亮度在术语上不加区别.

3.2.2 神经元之间的链接权

某神经元 i 的链接 L_i 是由与其链接的其它神经元的点火引起的, 且神经元 j 对这一链接的贡献反映在链接权 w_{ij} 上. 设计 w_{ij} 由两部分组成: (1) 由样本点的空域特性造成, 即距离越远贡献越小, 故可取

$$w'_{ij} = 1/d_{ij}^2 \quad (4)$$

(2) 由教师指导信号(即样本类属信息)造成的, 如果样本 i 与样本 j 属于同类, 即 $y_i = y_j$, 则这两个神经元之间应捕获点火(即相互激励), 若它们属于异类, 即 $y_i = -y_j$, 则这两个神经元之间应抑制点火(即相互抑制). 因此, 样本 i 与样本 j 之间的链接权可设计为

$$w_{ij} = y_i y_j w'_{ij} \quad (5)$$

从而样本 i 与样本 j 的距离越近/越远, 神经元 i 与神经元 j 的捕获/抑制作用就越强, 反之, 捕获/抑制作用就越弱, 且同类/异类样本之间存在捕获/抑制作用.

3.2.3 捕获/抑制强度参数 β 的设计

参数 β 在 PCNN 行为中起着调节神经元之间捕获/抑制强度的作用. 那么, 如何选择 β 可以保证使所有 C_1 中的样本都先于 C_2 中的样本点火呢?

不失一般性, 设在所有训练样本中 C_1 中的样本最点火.

为保证 C_1 中所有样本都点火时, C_2 中的样本中最亮的样本仍未点火, 需

$$\max_k 2k(1 + \beta L_{1,2k}) < x_{\min}(1 + \beta L_{1,1\min}) \quad (6)$$

其中 $L_{1,2k}$ 为 C_1 中的所有样本都点火所造成的对样本 X_{2k} 的链接, x_{\min} , $L_{1,1\min}$ 分别表示 C_1 中的最暗样本 $X_{1\min}$ 的外部刺激以及 C_1 中的所有样本都点火所造成的对样本 $X_{1\min}$ 的链接. 因此有 $x_{2\max}(1 + \beta \sum_{j \in C_1} w_{j,2\max}) < x_{\min}(1 + \beta \sum_{j \in C_1} w_{j,1\min})$, 即

$$\beta > \frac{x_{2\max} - x_{\min}}{x_{\min} \sum_{j \in C_1} w_{j,1\min} - x_{2\max} \sum_{j \in C_1} w_{j,2\max}} \quad (7)$$

即当 β 选得满足式(7), 即可保证 C_1 中的所有样本总是先于 C_2 中的所有样本点火.

因此对两类问题的基于 PCNN 的分类器设计为: 依据各类样本之间的距离和类属信息运用式(3)获得 PCNN 的对应神经元的外部刺激 x_{ki} ; 依据样本之间的距离和类属信息运用式(5)获得 PCNN 的链接权; 选择满足式(7)的参数 β . 实际上, 运用训练样本在样本空间中的相互距离信息和样本类属信息获得 β 的过程即为分类器的设计过程, 它总能保证 C_1 中的所有样本总是先于 C_2 中的所有样本点火.

对于任一测试样本 X_l , 运用上述同样的过程可以获得假设 X_l 属于 C_1 的 x_{1l} 和假设 X_l 属于 C_2 的 x_{2l} , 依据分类器设计过程中所获得的 β , 可以得到该测试样本所对应的分属 C_1 和 C_2 的神经元的内部行为, 分别为

$$u_{1l} = x_{1l}(1 + \beta \sum_{j \in C_1} w_{j,1l})$$

$$u_{2l} = x_{2l}(1 + \beta \sum_{j \in C_2} w_{j,2l})$$

显然 $PCNN=1$ 在 $t=0$ 时刻所有神经元同时点火, 使所有神经元的阈值同时冲击到 V_0 , 并随时间同时以相同的时间常数 τ_0 指数下降, 即随着网络中各神经元阈值的下降, 网络总能保证 C_1 类样本先于 C_2 类样本点火, 因此, 若有 $u_{1l} > u_{2l}$, 则测试样本 X_l 属于 C_1 , 否则 X_l 属于 C_2 . 这实际上隐含了选取时间中值阈值作为时间阈值, 因此所获得的分类器是具有最大推广能力的稳健分类器.

3.3 多类模式的模式分类

上述基于 PCNN 的两类问题的分类器设计方法可直接推广到多类问题的情况, 其基本步骤是: (1) 以第 k 类训练样本最点火而其余训练样本都在其后点火设计捕获/抑制强度参数 β_k ; (2) PCNN 的最终捕获/抑制强度参数取为满足 $\beta \geq \max_k \beta_k$; (3) 对于任一测试样本 X_l , 假设 X_l 属于第 k 类 ($k=1 \sim K$), 可计算 X_l 在第 k 类训练样本上所对应神经元的外部刺激 x_{kl} , 从而第 k 类所有训练样本的点火所造成的该神经元的内部行为为

$$u_{kl} = x_{kl}(1 + \beta \sum_{j \in C_k} w_{j,kl}) \quad (8)$$

(4) 比较 u_{kl} , $k=1 \sim K$, u_{kl} 最大的 k 即为测试样本 X_l 的所属类别.

实际上, 我们所提出的基于 PCNN 的模式分类方法是与

人脑神经元的功能区域特性完全一致的. 生物神经学研究表明, 人的大脑皮层有功能区域性结构, 即大脑皮层存在许多不同的神经功能区, 每个区域都完成各自的功能; 每个功能区的神经网络中含有若干个神经元群, 它们则完成相应功能区的特定功能. 从大脑对模式的识别角度上看, 人脑的记忆不是神经元与记忆模式的一一对应, 而是一群神经元对应一个模式, 这种神经系统的自组织特性是在人的先天生物结构基础上通过后天的环境适应和学习得到的. 生理实验还表明, 某一外界信息所引起的兴奋刺激并不针对一个神经细胞, 而是对以某个神经元为中心的一个区域内的各个神经元的兴奋刺激, 并且刺激强度以区域中心为最大, 随着与中心的距离增大强度逐渐减弱, 远离中心的神经元反而还受到抑制, 即同一模式对应神经元区域内各个神经元之间是相互激励的, 不同模式的神经元区域之间则是相互抑制的. 我们正是在 PCNN 中引入侧激励(捕获同类样本)和侧抑制(抑制异类样本)链接, 在 PCNN 上形成模式功能区, 而未知模式的测试样本(神经元)则是通过各个功能区对其的竞争获得该测试样本的类属的. 因此, 本文提出的基于 PCNN 的模式分类方法很好地模拟了人脑的功能区域特性和神经区域之间的兴奋抑制规律.

显然, 上述基于 PCNN 的模式分类方法具有以下特点:

(1) 分类器的设计仅需一个参数(网络捕获/抑制强度 β) 的计算, 无须迭代训练从而没有局部极小点问题. 实际上, β 取得足够大即可; (2) 所设计的分类器结构简单, 即通过式(8)中的 u_{ij} 的计算及比较获得测试样本 X_i 的类属, 却不管训练样本的线性或非线性的可分程度, 因此可实现任意复杂分布训练样本的分类问题; (3) 由于是通过各模式功能区的竞争获得测试样本类属的, 所设计的分类器是具有最大推广能力的稳健分类器; (4) 无论是分类器设计和测试样本的类别预测, 都无需实际运行一个脉冲耦合神经网络. 实际上我们只是运用脉冲耦合神经网络神经元的捕获/抑制思想提出分类器设计的方法, 而没有真正运行网络, 也无需选择脉冲耦合神经网络众多的参数; (5) 分类器的设计和测试均无需真正获得样本空间中的每一样本, 而只需样本之间的距离, 这为该方法的某些特殊应用提供了条件(即在某些情况下只知道样本之间的距离, 而不知道样本在样本空间中的位置).

考虑到每类模式的训练样本数有可能不平衡, 我们进一步将式(3)修改为
$$x_i |_{i \in C_k} = \frac{1}{N_{k_j \in C_k}} \sum_{j \in C_k} \frac{1}{d_{ij}^2} \quad (9)$$

其中 N_k 为类 C_k 中的训练样本数. 另一种修改方式为

$$x_i |_{i \in C_k} = \frac{1}{N_{k_j \in C_k}} \sum_{j \in C_k} \exp(-\|d_{ij}\|) \quad (10)$$

值得指出的是, 该算法在计算样本对分布密度的贡献即式(3)、(9)或(10)时, 需计算样本间的距离, 这给大样本情况带来较大的计算量, 可通过设置门限使局部范围内有贡献、局部范围外无贡献来处理, 并且由于贡献的计算是一次性的和离线的, 因此不影响识别的响应速度.

4 实验与结果

我们对如下仿真数据、Iris 数据以及真实的微波暗室目标自动识别问题进行了分类器设计实验, 以讨论所设计的分类

器的性能. 在我们的实验中, β 取为 $\beta = 1000$.

4.1 简单分类问题

图 2(a)/(b) 是一个简单的类异或问题(每类 10 个样本)/四高斯分布 $N(0, 4; 1)$, $N(4, 0; 1)$, $N(0, 0; 1)$, $N(4, 4; 0.25)$ ($N(a, b; c)$ 表示均值为 (a, b) 方差为 c 的高斯分布) 所生成样本(每类样本点数各为 50)的分类问题及用 PCNN 分类器所找出的分类边界. 显然, 这样的分类边界能对训练样本进行分类, 且由于分类边界基本处于两类/四类邻近样本的中间, 所设计出的分类器为稳健分类器.

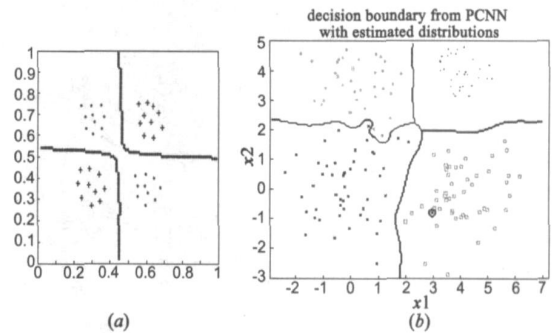


图 2 用本文方法所找出的两个简单分类问题的分类边界

4.2 复杂分类问题

双螺旋问题是典型的复杂非线性分类问题. 文献[21] 对于 5 圈双螺旋线(加噪

声) 每一类 300 个样本所获得的前向网络结构为 2-70-30-1, 即网络有 2 个输入、1 个输出、两个隐层, 第一、第二隐层分别有 70 和 30 个神经元, 网络参数共 $3 \times 70 + 71 \times 30 + 31 = 8461$ 个, 其所获得的分类界面示于图 3. 用本文方法对 5 圈的双螺旋问题(有噪声/无




图 3 文[21]中所获得的双螺旋问题(5圈)的分类边界

噪声情况) 所获得的分类边界示于图 4(a1)/(a2) 中. 显然, 所给出的分类边界即能对样本进行分类又处于两类相邻模式样本的中间, 实现了对应的稳健分类. 图 4(b1)/(b2) 则给出了更为复杂的三螺旋问题(5 圈) 无噪声/有噪声情况下的分类边界, 显然所得到的分类边界也具有稳健特性.

4.3 与 Bayes 分类器的比较

Bayes 分类器是一种经典的统计分类器, 需要数据的分布信息. 为比较方便, 我们分别通过高斯分布 $N(0, 0; 2)$ 和 $N(3, 3; 1)$ 产生两类每类各 100 个训练样本. 用本文方法训练获得分类边界和 Bayes 边界结果分别示于图 5(a)、(b) 中(虚线为 Bayes 边界, 实线为本文方法边界), 其中图 5(a)、(b) 的实线由本文方法及式(10)、式(9)获得的分类边界. 从图 5 可知, Bayes 分类器从统计(集体分布)上获得统计意义下的最优分类边界, 而本文方法则从训练样本(个体)上获得错误识别率

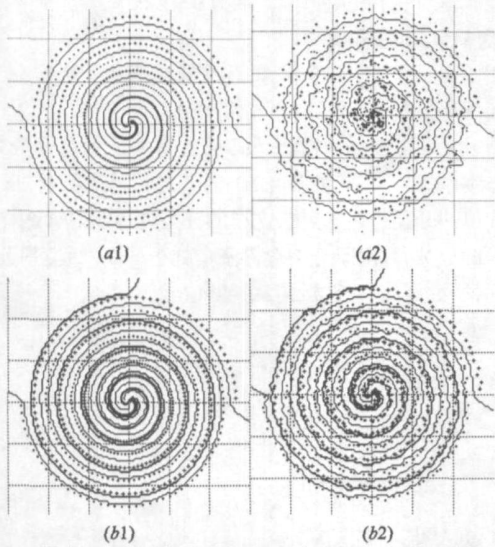


图 4 用本文方法所获得的 (a) 双螺旋问题 (5 圈); (b) 三螺旋问题 (5 圈) 的分类边界, 其中左图为未加噪声情况下, 右图为在螺旋线上加入了噪声情况下的分类边界

最小(这里为 0)的最优分类边界(图 5 (b)), 前者强调训练数据的整体信息, 后者强调训练数据的个体信息, 而以式 (10) 作为外部刺激的本文方法则综合了训练样本的统计信息(集体分布)和训练样本的个体信息(图 5 (a)). 当训练数据足够充分时训练样本本身就体现了其中的集体信息. 从图 5 (a) 与 (b) 的比较看出, 用本文方法和式 (10) 时分类边界更为平滑, 能有效消除训练样本中坏点(Outlier)的影响, 更具有实用性.

我们对典型的 Iris 数据进行了识别实验. Iris 数据是从三种类型的鸢尾属植物每种 50 个样本所获得的植物萼片长度宽度、花瓣长度宽度数据, 故数据特征为 4 维, 共 150 个样本, 3 类. 我们用每类的前 40 个样本作为训练数据, 其余作为测

试数据, 用本文方法进行识别, 对测试数据的三类样本均获得了 100% 的正确识别率.

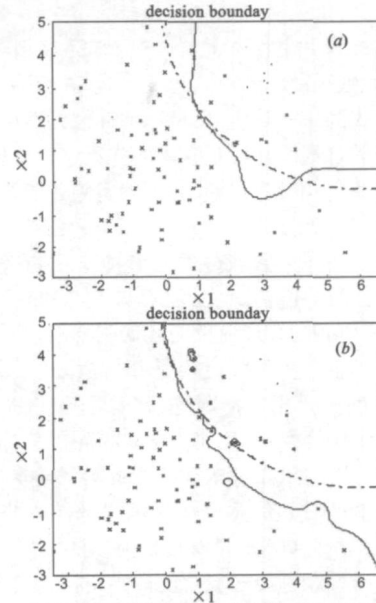


图 5 用本文方法所获得的分类边界 (实线) 和用 Bayes 方法所获得的分类边界 (虚线), (a) 当用式 (10) 时; (b) 当用式 (9) 时

4.4 微波暗室自动目标识别实验

我们对在微波暗室所获得的 B-52, Q-6, Q-7 三种飞机模型的实测一维距离像(依方位分别得到了 322, 310, 451 个距离像, 每个像的维数是 101 维)进行了自动目标识别. 通过对这些距离像的 DCA (Discriminate Component Analysis) 投影^[10], 将其投影到 Fisher 指标的前两个和前三个主分量上(示于图 6 (a1) 和 (a2)), 可以看出, 各类数据之间混叠非常严重, 给目标识别带来了极大困难. 为此, 我们提出了一种基于非负

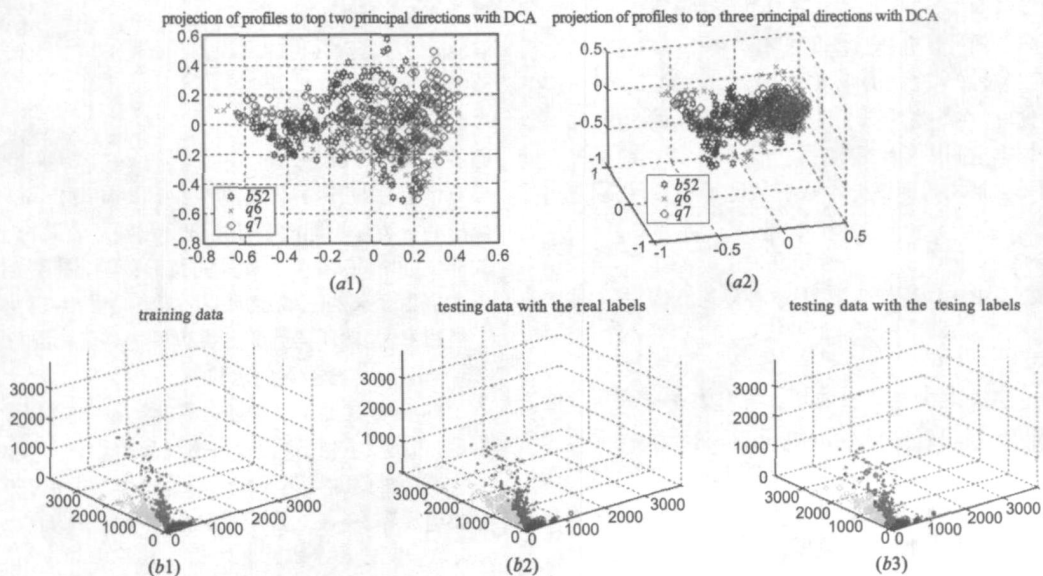


图 6 (a) 雷达距离像在 DCA 前两个/前三个分量上的投影; (b) 类别空间中的训练样本 (b1), 测试样本 (b2), 本文方法对测试样本的识别结果 (其中打 x 的样本为被错误分类的样本, 其余样本被正确分类) (b3)

矩阵分解(NMF, Non-negative Matrix Factorization)^[20]的特征提取方法(对每一类取其 NMF 参数 $r = 30$), 将每一目标的距离像通过 NMF 投影到这一目标的特征子空间中, 并计算该距离像到三类目标特征子空间的重构误差, 构成三维类别空间中的一个点, 图 6(b1) 和 (b2) 分别示出了训练样本和测试样本在类别空间中的投影结果. 表 1 示出了本文方法(并用式(10), $\beta = 10000$)和 SVM、RVM 方法(均采用多项式核)的识别结果, 其中的 SVM 和 RVM 是经过多次调整 SVM、RVM 参数获得的最好结果.

表 1 PCNN 方法、SVM 方法和 RVM 方法的比较

方法	训练样本识别率	测试样本识别率
本文方法	100	96.49
RVM		94.45
SVM	92.84	77.36

值得指出的是, 本文方法的训练样本识别率为 100%, 测试样本识别率有明显提高; 实际上, 所训练出的 SVM、RVM 分类器, 获得上述识别率的支持向量、相关向量数基本占到了训练样本总数的 2/3 甚至更多, 使训练出的 SVM 和 RVM 分类器结构极其庞大, 实现困难, 而本文方法训练出的分类器结构简单得多.

5 结论

本文提出了一种对复杂混叠模式进行模式分类的崭新方法, 这种方法的特点是: (1) 所设计的分类器结构简单, 却可实现任意复杂分布训练样本分类问题的最稳健分类; (2) 分类器的设计仅需一个参数(网络捕获强度)的计算, 无须迭代训练从而没有局部极小点问题; (3) 无论是分类器设计和测试样本的类别预测, 都无需实际运行脉冲耦合神经网络. 大量仿真实验、Iris 数据识别实验和微波暗室自动目标识别实验结果验证了这一方法的可行性和有效性.

参考文献:

- [1] Anil K Jain, Robert P W Duin, Mao Jianchang. Statistical pattern recognition: a review[J]. IEEE Trans, 2000, PAMI 22(1): 4-37.
- [2] Simon Haykin. Neural Networks: A Comprehensive Foundation, 2nd Edition[M]. New Jersey: Prentice Hall Inc, 1999.
- [3] Eric Mjolsness, Dennis DeCoste. Machine learning for science: state of the art and future prospects[J]. Science, 2001, 293(14): 2051-2055.
- [4] Zhang Junying. Classification hyperplane theory for the analysis of binary feedforward neural networks[D]. Xi'an: Xidian University, 1998.
- [5] Bose N K, Liang P. Neural Network Fundamentals with Graph, Algorithms and Applications[M]. New York: McGraw-Hill Inc, USA, 1996.
- [6] B D Ripley. Pattern Recognition and Neural Networks[M]. United Kingdom: Cambridge University Press, first published 1996, reprinted 1997, 1999.
- [7] Vapnik V. Statistical Learning Theory[M]. New York: Wiley, USA, 1998.
- [8] Isabelle Guyon, Jason Weston, Stephen Bamhill, Vladimir Vapnik. Gene selection for cancer classification using support vector machines[J]. Machine Learning, 2002, 46(3): 389-422.
- [9] Michall E Tipping. Sparse Bayesian learning and relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1: 211-244.
- [10] Zhang Junying, Yue Joseph Wang, Javed Khan, Rober Clarke. Gene selection in class space for molecular classification of cancer[J]. Science in China, Ser F Information Sciences, 2004, 47(3): 301-314.
- [11] Eckhorn R, Reiboeck H J, Arndt M, et al. A Neural Networks for Feature Linking via Synchronous Activity: Results from Cat Visual Cortex and from Simulations, in Models of Brain Function (ed Cotterill R M J) [M]. Cambridge: Cambridge Univ Press, 1989.
- [12] P Eckhorn. Neural mechanisms of scene segmentation: recordings from the visual cortex suggest basic circuits or linking field models[J]. IEEE Trans, 1999, NNs 10(3): 464-479.
- [13] R P Broussard, S K Rogers, M E Oxley, G L Tarr. Physiologically motivated image fusion for object detection using a pulse coupled neural network[J]. IEEE Trans, 1999, NNs 10(3): 554-563.
- [14] J M Kinser. Foveation by a pulse coupled neural network[J]. IEEE Trans, 1999, NNs 10(3): 621-625.
- [15] H J Caufield, J M Kinser. Finding the shortest path in the shortest time using PCNN's[J]. IEEE Trans, 1999, NNs 10(3): 604-606.
- [16] Karvonen Juha, Similae Markku. Pulse coupled neural network for sea ice SAR image segmentation and classification[A]. Thomas Lindblad. Proc SPIE[C]. US: Pergamon Press, 1999. 3728:333-350.
- [17] 张军英, 王德峰, 石美红. 输出阈值耦合神经网络及基于此的最短路问题求解[J]. 中国科学, 2003, 33(6): 522-530.
- [18] J L Johnson. Pulse coupled neural nets: translation, rotation, scale, distortion and intensity signal invariance for images[J]. Appl Opt, 1994, 33(26): 6239-6253.
- [19] Zhang Junying, Lu Zhijun, Shi Lin, Dong Jiyang, Shi Meihong. Filtering images contaminated with Pep and salt type noise with pulse coupled neural networks[J]. Science in China, Ser F, Information Sciences, 2004, 47(3): 301-314.
- [20] Daniel D Lee, H Sebastian Seung. Learning the parts of objects by non-negative matrix factorization[J]. Nature, 1999, 401: 788-791.
- [21] 范卫平, 张立明. 用多层 perceptron 网络解复杂分类问题的一种自适应算法[A]. D S Huang. Proceedings of 1997 Chinese Congress on Neurocomputing Science (CCNS' 97)

[C]. 南京: 人民邮电出版社, 1997. 26- 28.

[22] Gollamudi A, Calvin P, Yuen G, Malkani M. Pulse coupled neural network based image classification[A]. IEEE Proceed

ings of the Thirtieth Southeastern Symposium on System Theory[C]. US: Pergamon Press. 1998. 402- 406.

作者简介:



张军英 女, 1961 年 11 月生于西安, 博士, 教授, 博导, IEEE 会员, 中国电子学会高级会员, 中国计算机学会高级会员, 西安电子科技大学学科带头人, 西安理工大学自动控制专业学士(1982 年), 西安电子科技大学计算机应用专业硕士(1985 年), 西安电子科技大学信号与信息处理专业博士(1998 年). 2001-2002 年受国家留学基金委选派在美国作访问学者, 2004 年 2 月至 4 月赴香港中文大学做访问学者. 目前主要从事计算生物信息学、分子成像、DNA 微

阵列数据分析、人工神经网络、模式识别、遗传算法、智能信息处理和图像处理等方面的研究工作, 已发表学术论文 60 余篇.

E-mail: jzhang@xidian.edu.cn

梁军利 男, 1978 年 6 月生于北京, 2001 年西安电子科技大学计算机应用专业硕士研究生, 研究方向为智能信息处理; 2003 年底考取中国科学院声学所博士研究生. 主要感兴趣的方向为模式识别、智能信息与信号处理. E-mail: liang_2001@263.sina.com

保铮 男, 1927 年生于江苏南通, 1953 年毕业于解放军通信工程学院, 现在是中国科学院院士、中国电子学会会士和雷达信号处理重点实验室学术委员会主任, 研究方向为雷达信号处理与检测.

E-mail: zhao@xidian.edu.cn