

基于仿生模式识别和 PCA/ICA 的 DOA 估计方法

安冬,王守觉

(中国科学院半导体研究所神经网络实验室,北京 100083)

摘要: 本文提出了一种基于仿生模式识别和 PCA/ICA 的 DOA 估计方法. 这种方法的建模过程是在实际环境下采集的训练样本构造神经网络模型,对环境的适应能力较强;且这种方法采用 PCA/ICA 进行特征提取,使数据得到有效压缩,可以实现系统实时处理. 实验结果表明:在信噪比为 20dB 和 0dB 时,该方法的正确估计率可达 100%;在信噪比降为 -20dB 时,该方法仍有 83% 的可识别率.

关键词: DOA 估计; 仿生模式识别; 神经网络; PCA; ICA

中图分类号: TNTP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2004) 09-1448-04

A DOA Estimation Method Based on Biomimetic Pattern Recognition and PCA/ICA

AN Dong, WANG Shou-jue

(Lab of Artificial Neural Networks, Institute of Semiconductors, CAS, Beijing 100083, China)

Abstract: The applicability of biomimetic pattern recognition to information processing of abstract objects is studied, and then a DOA estimation method based on biomimetic pattern recognition and PCA/ICA is advanced. In this method, the output signals of antenna array are collected in practical conditions and expressed as feature vectors by using PCA/ICA. These feature vectors are studied with the method of high dimensional geometry and the principle of biomimetic pattern recognition. By using the feature vectors as training samples ANN models are constructed. In our experiments, when SNR is 20dB or 0dB, the correct estimation rate is 100%; when SNR is -20dB, the correct estimation rate is 83%; The experimental results show that the proposed method has the great advantage of preferable robustness and fast computation.

Key words: DOA estimation; biomimetic pattern recognition; neural networks; PCA; ICA

1 引言

所谓 DOA 估计就是利用天线阵列接收信号源发出的信号,运用现代信号处理方法估计出信号源所在的方位,即在信号源情况未知的条件下,利用天线阵列输出(为一包含有信号源方位信息的复合矢量信号)估计出信号源方位. 解决这个问题可以从两个角度考虑:一个角度是建立数学模型、通过解析计算得出结果,如传统的 MUSIC 法、ESPRIT 法等. 近年来,基于这种思路的 DOA 估计取得了丰硕的成果,但这些理论上很好的算法大都停留在实验室仿真上,很难在实际工程中应用. 其根源在于以下两点:一是算法运算量大,无法实时实现;二是对实际应用环境的适应性差,达不到要求的性能指标. 另一个解决 DOA 估计问题的思路是采用“软建模”、“软计算”的方法,如人工神经网络、模糊集合理论、进化计算等等. 本文采用的是一种基于人工神经网络的方法. 这种方法的建模过程是用训练样本构造神经网络模型,而不是建立严格精确的数学方程式. 在实际情况下采集的训练样本已经将噪声、信噪

比、信号模型、传输通道等因素考虑了进去,因此可以较好的解决这些问题. 且这种方法在计算时采用了 PCA/ICA 进行特征提取,有效的压缩了数据,计算量较小,可以实现系统实时处理,从而有望应用于实际工程.

现实世界中的大多数事物(包括抽象事物在内)都可以通过若干特征来描述,从而形成一个表征该事物的特征矢量,对特征矢量可以有不同的分析方法. 多年来,人们多使用代数的方法对特征矢量进行分析^[1~4],而王守觉院士最近提出了一种高维空间几何分析方法^[5],并在此基础上提出了一种模式识别新理论——仿生模式识别(拓扑模式识别)^[6]. 基于上述思路本文提出了一种基于仿生模式识别和 PCA/ICA 的 DOA 估计方法,其基本原理为:将包含有信号源方位信息的天线阵列输出信号用特征矢量来表征,使用高维空间几何分析方法、仿生模式识别原理及 PCA/ICA 对特征矢量进行处理,实现对空间角度这一抽象对象的识别. 其实现方法是将空间角度分割成许多细小的连续的等份,每一等份对应一个神经元,即每个神经元表征一个可分辨的信号源方位,神经网络的作用是

判别信号方位是哪个神经元所表征的信号源方位,从而间接实现 DOA 估计.

2 仿生模式识别(拓扑模式识别)及 PCA/ICA 基本原理简介

2.1 仿生模式识别(拓扑模式识别)

以往,人们在研究模式识别问题时,考虑的出发点都是怎样利用统计决策理论对若干有限类别的样本进行最优分类划分(包括支持向量机)^[1~4].而王守觉院士提出的仿生模式识别(拓扑模式识别)是利用高维空间几何分析方法对一类一类样本进行“认识”.图 1 为仿生模式识别与传统模式识别的比较.

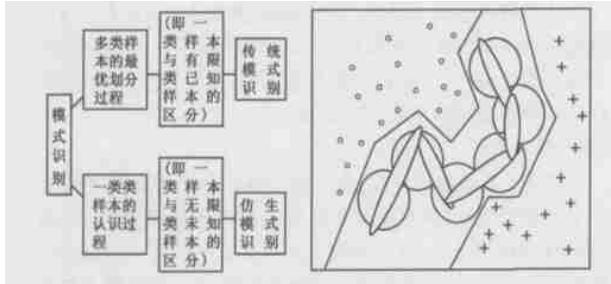


图 1 传统模式识别与仿生模式识别的区别 图 2 划分方式与认识方式的区别

基于上述思想,仿生模式识别是以一类样本在特征空间中分布的最佳覆盖为目标,不同于传统模式识别以不同类样本在特征空间中的最佳划分为目标,现以二维空间为例说明,见图 2.

图 2 中,三角形为要识别的样本,圆圈和十字形为与三角形不同类的两类样本,折线为 BP 网络的划分方式,大圆为 RBF 网络的划分方式(等同于模板匹配的认识方式),细长椭圆形构成的曲线代表仿生模式识别的“认识”方式.

基于特征空间中同类样本分布的连续性规律,对一类事物的“认识”,实质上就是对这类事物的全体在特征空间中形成的无穷点集合的“形状”的分析和“认识”.仿生模式识别就是利用点集拓扑学中关于高维流形的理论,研究特征空间中同类样本集的拓扑属性,从而对这类样本在特征空间中的分布状况加以合理覆盖.

在仿生模式识别中,任何一类事物全体连续映射到特征空间 R^n 中的“像”所组成的点集都被视为一个闭集 A .仿生模式识别的具体应用对象不同,集合 A 可以是不同维度的流形.识别过程就是判别某一被识别事物映射到特征空间 R^n 中的“像”是否属于集合 A .这就必须在特征空间 R^n 中构筑一个能覆盖集合 A 的 n 维空间几何形体.一个神经元可以是一个复杂的封闭超曲面^[7],多个神经元组合起来的人工神经网络就可以实现高维空间复杂几何形体覆盖.因而,人工神经网络是实现仿生模式识别的十分合适的手段.

2.2 PCA(Principal Components Analysis,主元分析)^[9]

主元分析对由一系列观测数据向量组成的向量组进行分析,找到最能表达该组向量特征的一组正交基,且使基的个数

尽可能的少.这组最能表达该组向量特征的正交基被称为“主元”.将该组向量投影到这组正交基上,该组向量的维数在投影后将会得到压缩.具体的算法由于篇幅的原因这里不再详细介绍.

2.3 ICA(Independent Components Analysis,独立元分析)^[9]

独立元分析同样是对由一系列观测数据向量组成的向量组进行分析,但它找出的是最能表达该组向量特征的一组非正交基,这将具有更大的通用性和适应性.这组最能表达该组向量特征的非正交基被称为“独立元”.主元分析可作为独立元分析的预处理,用来得到最能反映数据特征的维数,确定独立元的个数.独立元分析的算法有很多,本文是利用四阶统计信息求出独立元的,具体的算法这里不再详细介绍.

3 DOA 估计问题的数学模型

虽然本文所采用的方法是一种基于仿生模式识别的方法,这种方法的建模过程是用训练样本构造人工神经网络模型,而不是建立严格精确的数学方程式.但是仿生模式识别是通过研究特征空间中同类样本集的拓扑属性,对这类样本在特征空间中的分布状况加以合理覆盖来“认识”这类样本的.所以研究仿生模式识别的具体实例首先要分析被识别事物映射到特征空间中的“像”的分布状况,因此对 DOA 估计问题的数学模型进行分析是十分必要的.

为了分析推导的方便,现作以下假设:

- (1) 信号源为窄带的,且具有相同的中心频率 ω_0 .待测信号源的个数为 D .
- (2) 天线阵列是由 M 个阵元组成的等间距直线阵,阵元间距为 d .
- (3) 各阵元上有互不相关、方差为 σ_n^2 、均值为零的高斯白噪声.
- (4) 阵列响应在观测时间内是时不变的.

则单源 DOA 估计问题的数学模型如下:

$$X = S(t)A + N = S(t) \begin{bmatrix} 1 \\ e^{-j(2d/\lambda)\sin\theta} \\ \dots \\ e^{-j(M-1)(2d/\lambda)\sin\theta} \end{bmatrix} + N \quad (1)$$

其中, $X = [x_1(t), x_2(t), \dots, x_M(t)]^T$

$$N = [n_1(t), n_2(t), \dots, n_M(t)]^T$$

X 为天线阵列输出, $S(t)$ 为信号的包络, A 为信号的方向向量, N 为噪声.

据阵列响应在观测时间内时不变假设, $S(t)$ 为一常数, d 为常数(通常取 d/λ 为 $1/2$),如不考虑噪声 N 的影响,可以将阵列输出 X 看成是一个关于 θ 的函数,记作 $X = X(\theta)$.所以 X 经连续变换后,在特征空间中形成的“像”近似于一个一维流形 P .加以噪声 N 的影响,可以考虑在特征空间中的覆盖形状是一个一维流形 P 与 n 维超球的拓扑乘积 P_a :

$$P_a = \{x | (x, y) \leq k, y \in P, x \in R^n\} \quad (2)$$

(x, y) 为 x, y 之间的距离, k 为选定的距离常数,即在 n 维

特征空间中,离一条空间曲线的距离小于等于某定值 k 的所有点的集合.

4 基于仿生模式识别的 DOA 估计方法

4.1 基于 PCA/ICA 的预处理

使信号源以天线为中心缓慢旋转一定角度范围(如从 30 度旋转到 40 度),向一个 m 元天线阵列发射信号.同时每隔一定角度间隔 (Δ 为一自定常数,通常可以设为 1 度)对阵列输出进行 n 点采样,产生一个 $m \times n$ 维矩阵 X :

$$X = [X(1), \dots, X(n)] \quad (3)$$

将此矩阵以列为基础,列与列按顺序首尾相接成为一个 $m \times n$ 维的列向量,这样就在 $m \times n$ 维测量空间中形成了一个样本点.针对所有被采样的角度,就形成了一个 $m \times n$ 行 c 列的矩阵 H , c 为被采样的角度总数,这样就在 $m \times n$ 维测量空间中形成了多个样本点,组成了测量样本集 O .

首先对矩阵 H 做 PCA^[9], 求出其主元 $U = [u_1, \dots, u_d]$, d 为主元个数,一般 $d < c$, u_i 为一个 $m \times n$ 维的列向量.则通过计算 $G = U^T H$ 就将测量空间中的样本点变换到了由主元 U 组成的新坐标系中. G 为一个 $d \times c$ 的矩阵,其每一个列向量为 d 维主元坐标系中的一个样本点.这时,样本点的维数由原来的 $m \times n$ 维,降到了 d 维.

然后利用四阶统计信息对 G 做 ICA^[9], 求出其独立元 $V = [v_1, \dots, v_d]$, 再通过计算 $F = V^T G$ 将主元坐标系下的样本点变换到由独立元 V 组成的新坐标系中. F 为一个 $d \times c$ 的矩阵,其每一个列向量为 d 维特征空间中的一个样本点,整个的 F 矩阵形成了原始样本集 S .这样就完成了从 $m \times n$ 维测量空间到 d 维特征空间的变换,实现了降维和特征提取的目的.

4.2 神经网络结构构造

根据第 3 节的分析,原始样本集在特征空间中的覆盖形状应是一个一维流形 P 与 m^2 维超球的拓扑乘积 P_a ,即

$$P_a = \{x | (x, y) \leq k, y \in P, x \in R^n\} \quad (4)$$

$$S = \{x | x = S_i (i = 1, 2, \dots, \text{采集样本总数})\}, \\ S \subset P, P \subset R^n, n = m^2 \quad (5)$$

为了使用较少的神经元近似覆盖 P_a ,现用若干空间直线段近似空间曲线 P .每个神经元覆盖的是一个直线段与 m^2 维超球的拓扑乘积.具体方法如下

在原始样本集 S 中选取 j 个样本组成训练样本集 S_j ,

$$S_j = \{x | x = s_i (i = 1, 2, \dots, j), (s_j, s_{j+1}) = (s_{j+1}, s_{j+2}) = d\} \quad (6)$$

$S_j \subset S$, d 为设定常数

用 $j-1$ 个神经元来近似覆盖 P_a ,第 i 个神经元的覆盖范围 P_i 为

$$P_i = \{x | (x, y) \leq k, y \in B_i, x \in R^n\}, n = m^2 \quad (7)$$

$$B_i = \{x | x = s_i + (1 - \alpha) s_{i+1}, \alpha \in [0, 1]\} \quad (8)$$

即某一角度范围内的样本点,该神经元对应于一个可分辨的信号源方位.

为了实现对 P_i 的覆盖,本文采用了一个形状类似香肠的

神经元.^[7,8]

$$y_i = f[\alpha (s_i, s_{i+1}, x)] \quad (9)$$

式中 s_i, s_{i+1} 为第 i 和 $i+1$ 个训练样本; x 为输入样本; y_i 为第 i 个神经元的输出.

$$(s_i, s_{i+1}, x) = (x, y), x \in R^n$$

$$Y = \{z | z = s_i + (1 - \alpha) s_{i+1}, \alpha \in [0, 1]\} \quad (10)$$

$f[\cdot]$ 为一阈值函数,全部 $j-1$ 个神经元形成的覆盖区域为

$$P_a = \bigcup_{i=1}^{j-1} P_i \quad (11)$$

这样,连续对应于 $j-1$ 个可分辨信号源方位的 $j-1$ 个神经元完成了对 P_a 的近似覆盖.

4.3 样本训练

从由训练样本 s_1 与 s_2 组成的直线段开始,在 d 维特征空间中训练覆盖该直线段与 d 维超球拓扑乘积 P_i 的神经元,直到完成所有 $j-1$ 个直线段对应的 $j-1$ 个神经元的训练.存储每个神经元的参数,完成训练.

4.4 样本识别

由 4.1 节的叙述可知,每个可分辨的信号源方位对应于一个神经元.现对所有神经元按所代表的空间角度的顺序进行编号,即所有的 $j-1$ 个神经元顺序表征了所有可分辨的信号源方位.神经网络的作用是判别带有角度信息的输入样本点落入到几号神经元的覆盖区域,则这个神经元所表征的可分辨的信号源方位即为信号入射的方位,从而完成 DOA 估计.具体来说,将某一输入样本点输入到神经网络中,得到所有 $j-1$ 个神经元的输出,如果该样本点落入神经网络所覆盖的区域 P_a 内,则其中输出值最小的神经元所对应的可分辨信号源方位即为信号入射的方位;如果该样本点没有落入神经网络所覆盖的区域,则信号入射的方位不是该神经网络可分辨的信号源方位.

5 实验过程及结果

使信号源 $y = \sqrt{2} \sin(500t)$ 向一个 8 元线阵发射信号,设置采样频率为 200Hz,采样点数为 100,对阵列输出进行采样,可得到一个 8×100 的矩阵.现使信号源围绕天线从 0 度缓慢旋转到 18 度,均匀采集 100 个样本,为第一测量样本集.(所谓均匀采集样本即每隔一定的角度间隔采集一次样本,本试验是每隔 0.18 度采集一次样本.)调整信噪比,再次使信号源围绕天线从 0 度缓慢旋转到 18 度,均匀采集 200 个样本,为第二测量样本集.使信号源围绕天线从 18 度旋转到 36 度,均匀采集 100 个样本,为第三测量样本集.

实验步骤如下:

(1) 按 4.1 小节的方法对第一测量样本集做 PCA/ICA 后即可在一个 6 维特征空间中形成特征样本集.在这个样本集中,每隔 1.8 度选取一个样本,共选取了 11 个样本,组成训练样本集.

(2) 用 10 个神经元实现对由这 11 个训练样本点所组成的折线段的覆盖,构造出识别网络,这个网络对空间角度的分辨率为 1.8 度.

(3) 对所有神经元进行依次编号,编号为 1, ..., 10.

(4) 将第一、第二、第三测量样本集中的所有样本按 4.1 小节的方法变换到 6 维特征空间后对这个网络进行测试, 结果见表 1。

(5) 如果测试样本点没有落入整个神经网络所覆盖的范围, 则为拒识, 如果落入网络中任一神经元的覆盖范围, 则为可识别的样本, 可识别时的平均误差 S 为:

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2} \quad (12)$$

其中, n 为测试样本总数, \hat{x}_i 为第 i 个样本的估计值, x_i 为第 i 个样本的真实值。

(6) 重新在特征样本集中, 等间距的选择 7 个样本, 即每隔 3 度选取一个样本, 组成新的训练样本集。用 6 个神经元实现对由这 7 个训练样本点所组成的折线段的覆盖, 构造出识别网络, 这个网络对空间角度的分辨率为 3 度。将第一、第二、第三测量样本集中的所有样本按 4.1 小节的方法变换到 6 维特征空间后对这个网络进行测试, 得出的试验结果见表 1。

表 1 基于仿生模式识别的 DOA 估计实验结果

神经元个数	10	10	10	10	6	6
距离常数 k	0.3	0.3	2.8	3.1	1	1
信噪比/dB	20	0	-20	-20	20	0
识别率/%	100	100	83	100	95	98
拒识率/%	0	0	17	0	5	2
识别是的平均估计误差/(°)	0	0	0.31	0.57	0	0

(7) 在目前的 DOA 估计工程中, 所使用的最先进的方法为 MUSIC 法。为了将基于仿生模式识别的方法和 MUSIC 法进行比较, 我们在同样的实验条件下 (即信号源相同, 天线阵列相同, 信噪比相同, 角分辨率取 1.8 度) 使用 MUSIC 法进行 DOA 估计。得出的实验结果和仿生模式识别法的实验结果比较如表 2 所示。

表 2 MUSIC 法和仿生模式识别法的估计性能比较

	信噪比 /dB	平均估计误差/(°)
MUSIC 法	20	0
	0	0.24
	-20	2.4
仿生模式识别法	20	0
	0	0
	-20	0.57

6 讨论与结论

由上述实验结果可以看出:

(1) 增加神经元的数量, 即增加神经元覆盖范围的复杂度, 可以改善估计效果。

(2) 针对较低的信噪比, 可以通过适当调大 k 值, 即调大神经元覆盖区域, 来改善估计效果。但是要注意, 随着 k 值的增大, 拒识率虽会下降, 但识别时的平均误差却会增大。

(3) 在同样的实验条件下, 基于仿生模式识别的 DOA 估

计方法要优于 MUSIC 法, 尤其在信噪比较低的情况下, 这种优势表现的更为明显。说明基于仿生模式识别的 DOA 估计方法对环境的适应性要比 MUSIC 法好, 更具有实用价值。

实验结果证明了以高维空间几何分析方法为基础的仿生模式识别不仅可以应用于传统的模式识别 (如实物识别、人脸识别、语音识别), 而且完全可以应用于非感性的抽象对象的信息处理 (如阵列信号处理)。且这种方法的建模过程是用训练样本构造神经网络模型, 鲁棒性很好, 估计时计算量较小, 可以实现系统实时处理, 从而有望应用于实际工程。这两点在信号处理领域具有普遍意义, 值得推广。

参考文献:

- [1] Fisher. Contributions to Mathematical statistics[M]. New York: J Wiley, 1952.
- [2] 陈季镛(美). 统计模式识别[M]. 邱炳章, 邱华, 译. 北京: 北京邮电学院出版社, 1989.
- [3] Vapnik and Chervonenkis. Theory of Pattern Recognition[M]. Nauka: Moscow, 1974.
- [4] Adimir N Vapnik. 统计学习理论的本质[M]. 张学工, 译. 北京: 清华大学出版社, 2000.
- [5] 王守觉, 等. 神经网络的多维空间几何分析及其理论[J]. 电子学报, 2002, 30(1): 1-4.
- [6] 王守觉. 仿生模式识别 (拓扑模式识别) ——一种模式识别新模型的理论与应用[J]. 电子学报, 2002, 30(10): 1417-1420.
- [7] 王守觉, 等. 通用神经网络硬件中神经元基本数学模型的讨论[J]. 电子学报, 2001, 29(5): 577-580.
- [8] 王守觉, 等. 基于仿生模式识别的多镜头人脸身份确认系统研究[J]. 电子学报, 2003, 31(1): 1-5.
- [9] 斯华龄(美). 智能视觉图像处理[M]. 上海: 上海科技教育出版社, 2002.

作者简介:



安冬女, 1977年1月生于河北省石家庄市, 博士生, 主要研究方向为模式识别、神经网络、信号处理。



王守觉男, 1925年6月生于江苏省苏州市, 研究员, 中科院院士, 电子学报主编, 主要研究方向为模式识别与神经网络模型、算法、硬件和应用。