

文章编号:1001-9081(2009)03-0798-03

数字信号调制识别的 RBFNN 分类器算法研究与实现

李园敏, 江桦, 李霞

(信息工程大学 信息工程学院, 郑州 450002)

(minzhongtian@163.com)

摘要:提出了一种新的用于数字信号调制识别的径向基函数神经网络(RBFNN)分类器算法。该算法采用减法聚类算法和最小均方算法实现了对隐含层中心点个数及位置和输出层权值系数的自适应训练。此算法能够综合考虑所有特征参量,能够在多维空间内找到最佳分界面;同时,解决了隐含层中心点个数及位置的盲目性和随机性的问题。仿真实验表明,在相同特征参量情况下,该算法能够有效提高正确识别率。

关键词:径向基函数神经网络;减法聚类;最小均方算法

中图分类号: TN911.72 **文献标志码:** A

Research and implementation of RBFNN classification algorithm for digital signal modulation recognition

LI Yuan-min, JIANG Hua, LI Xia

(Institute of Information Engineering, Information Engineering University, Zhengzhou Henan 450002, China)

Abstract: A new Radial Basis Function Neural Network (RBFNN) classification algorithm for the digital signal modulation recognition was proposed. Subtraction clustering algorithm and Least Mean Square (LMS) algorithm were used to adaptively train the number and location of the hidden layer center and the weight coefficient of output layer considering all the characteristic parameters, and the best interface in the multi-dimensional space could be found. Meanwhile, the blindness and randomness of the number and position of the hidden layer center were avoided. The simulation results show that the algorithm can improve correct recognition rate with the same characteristic parameters.

Key words: Radial Basis Function Neural Network (RBFNN); subtraction clustering; Least Mean Square (LMS) algorithm

0 引言

随着通信技术的发展,信道环境的日益复杂,通信信号在很宽的频带上采用各种调制方式。如何有效地识别和监视这些信号,在民用和军事领域都具有重要的现实意义和广泛的应用前景。

目前,统计模式识别方法作为应用最为广泛的数字信号调制识别方法,它主要由前端预处理、特征提取、分类器设计三部分组成。其中分类器设计部分是获得较高正确识别率的前提基础。分类器设计方法大致可分为基于判决树的分类器设计方法^[1]和基于人工神经网络的分类器设计方法^[2-3]。

神经网络作为一种以自组织、自适应和大规模分布式并行计算为特征的非线性系统,具有强大的模式识别能力和泛函逼近能力^[4]。与传统判决树方法相比,人工神经网络分类器设计方法具有自适应能力强、鲁棒性好、能够在多维空间内寻找最佳分界面的特点,能够有效提高正确识别率。文献[2]将支持向量机神经网络应用于调制识别。该方法用于多级分类,实现每一级两类间距离最大化,提高了正确识别率,但该方法不能同时综合考虑所有特征参量。文献[3]采用综合学习向量机和支持向量机神经网络实现类内欧式距离的最小化,但该方法对初始中心点的选取较为敏感。文献[5]应用 BP 神经网络实现分类器的设计,但此方法收敛速度较慢,存在局部极小值问题。本文提出了一种新的径向基函数神经

网络(Radius Base Function Neural Network, RBFNN)分类器设计方法。此算法采用减法聚类算法和最小均方(Least Mean Square, LMS)算法实现了 RBFNN 分类器的隐含层和输出层的自适应训练。通过对 MPSK 信号高阶统计量特征的提取和 RBFNN 分类器的设计实现了在较低的信噪比条件下的多进制相移键控(M-array Phase Shift Keying, MPSK)信号的子类识别,验证了该算法的有效性。

1 信号模型

假设接收信号经过加性高斯白噪声(Additive White Gaussian Noise, AWGN)信道传输,且已经完成载波同步和码元同步,但存在未知的参考相位偏差。接收端经过数字下变频后输出的采样复基带信号序列可表示为:

$$r_k = x_k + n_k; k = 1, 2, \dots, N \quad (1)$$

其中: N 是观测信号长度, r_k 是接收信号, n_k 是均值为0、方差为 N_0 的复高斯过程, x_k 是传输复基带信号。MPSK 信号表达式如下:

$$x_k = \sqrt{E} e^{j\theta} a_k; a_k \in \left[e^{\frac{j2\pi(m-1)}{M}}, m = 1, \dots, M \right] \quad (2)$$

其中: M 是信号的调制阶数, E 是信号能量, θ 为接收信号载波相位偏差。定义信噪比为 $10 \lg(E_b/N_0)$, E_b 为每比特信息能量。

2 特征提取与选择

特征选择与提取的目的是从众多的特征中选出一组抗噪

收稿日期:2008-09-05;修回日期:2008-11-13。

作者简介:李园敏(1985-),男,江西乐平人,硕士研究生,主要研究方向:通信信号调制识别、盲均衡算法;江桦(1956-),男,江苏南通人,教授,博士生导师,主要研究方向:通信信号处理、电磁频谱监测;李霞(1977-),女,辽宁鞍山人,博士研究生,主要研究方向:数字信号调制识别、人工神经网络在信号处理中的应用。

性能强、顽健性好、表征类别差异信息显著的特征参量。由于高阶累积量具有对噪声不敏感、表征类别差异显著等特点,本文采用了高阶累积量特征实现对 MPSK 信号识别。

文献[1]给出了不同阶数 MPSK 高阶累积量 C_{40} 、 C_{41} 、 C_{42} 理论值。如表 1 所示。

表 1 MPSK 信号高阶累积量理论值

信号	C_{42}	C_{41}	C_{40}
2PSK	$-2E^2$	$-2E^2$	$-2E^2$
4PSK	$-E^2$	0	E^2
MPSK, $M \geq 8$	$-E^2$	0	0

其中,针对 $M > 8$ 的 MPSK 信号可通过四次方实现对信号进行降阶处理,但每四次方运算会带来 12 dB 的信噪比损失^[6]。

构造如下定义的特征向量^[6]:

$$f_{x1} = C_{40}/C_{42}, f_{x1} = C_{41}/C_{42}, \mathbf{F}_x = [f_{x1}, f_{x2}] \quad (3)$$

通过对高阶累积量 C_{40} 、 C_{41} 、 C_{42} 取模和比值运算,能够使特征向量 \mathbf{F}_x 对信号能量、星座图的旋转具有不变性。特征向量 \mathbf{F}_x 理论值如下:

$$\mathbf{F}_{\text{MPSK}} = \begin{cases} [1, 1], M = 2 \\ [1, 0], M = 4 \\ [0, 0], M \geq 8 \end{cases} \quad (4)$$

3 分类器的设计

分类器的根本任务就是根据某一准则把一给定的由特征向量表示的输入模式映射到一个适当的模式类别^[5]。对于这种 SNR 变化范围较大的接收数字信号,除了提取抗干扰、易识别的特征外,良好的分类器也是获得较高正确识别率的前提基础。

3.1 径向基函数神经网络的结构

径向基函数神经网络是一种前向神经网络。网络结构由三部分组成:第一层为输入层,对应于输入特征矢量;第二层为隐含层,主要实现由输入层低维不可分到隐含层高维可分的空间映射;第三层为输出层,即对隐含层输出的线性加权。其网络拓扑结构^[4]如图 1。




图 1 径向基函数神经网络拓扑结构

3.2 径向基函数神经网络分类器的工作原理

假定待识别信号的调制方式为 A_1, A_2, \dots, A_m 共 m 种,

调制识别的任务就是对任意信号其调制方式 $x \in \bigcup_{i=1}^m A_i$, 设计分类决策 $f(\lambda)$, 实现由输入模式到输出向量的映射 $A_k \rightarrow e_k$ 。其中 λ 是 RBF 网络中需要训练确定的参数, e_k 是模式 A_k 对应的输出向量。

设训练集为: $TS = \{(x_p, d_p) \in \bigcup_{i=1}^m A_m \times e_j\}$, 其中, $p = 1,$

$\dots, N_s, j = 1, \dots, m$ 。

训练目标: $\forall x_k \in A_k \Rightarrow f(x_k; \lambda) = e_k$ 。

误差函数: $E(\lambda) = \sum_{(x_p, d_p) \in TS} [d_p - f(x_p; \lambda)]^2$ 。

判别输出:任一给定模式 $x_p \in A_k (k = 1, \dots, m)$, 取 $k = \arg \min_k |f(x_p, \lambda) - e_k|$ 。

3.3 RBFNN 的训练

RBF 神经网络的训练包含两部分:隐含层的训练和输出层的训练。其中隐含层训练主要是中心点个数及位置和宽度 σ 值的确定,输出层训练主要是确定权值向量矩阵 \mathbf{W} 。

3.3.1 隐含层的训练

本文采用减法聚类算法实现隐含层的训练。相比传统的随机确定中心法和 K 邻近聚类算法隐含层训练方法,减法聚类具有对初始中心点位置不敏感、中心点的个数及位置能够自适应地调整设定的优点。

令 $\{x_1, x_2, \dots, x_n\} \subset \mathbf{R}^i$ 是训练样本集, i 是输入样本空间维数, n 是样本个数。减法聚类算法^[7]如下:

1) 计算参数 γ_a, γ_b 。其中: $\gamma_a = \frac{1}{2} \min_i \left\{ \max_i \|x_i - x_k\| \right\}, \gamma_b = 1.25\gamma_a$ 。

2) 对每个输入训练样本,计算初始密度指标 $D_i = \sum_{j=1}^n \exp\left(\frac{-\|x_i - x_j\|}{(0.5\gamma_a)^2}\right)$, 选出密度指标最大的样本点作为第一个聚类中心 x_{c1} 。

3) 假定 x_{ck} 为第 k 次选出的聚类中心,相应的密度指标为 D_{ck} , 对每个数据点的密度指标按公式 $D_i = D_i - D_{ck} \exp\left(\frac{-\|x_i - x_{ck}\|^2}{(0.5\gamma_b)^2}\right)$ 进行修正,选出密度指标最高的样本点作为新的聚类中心 x_{ck+1} 。

4) 判断 $D_{ck+1}/D_{c1} < \delta$ 是否成立。若成立则退出,否则转到(3),其中 δ 是事先给定的参数,此参数决定了最终产生的聚类中心的数目, δ 越小,则聚类数目越多。

宽度 σ 的确定^[8]: $\sigma = d_{\max}/\sqrt{2n_r}$ 。其中, d_{\max} 为各中心间的最大距离, n_r 为中心点的个数。

3.3.2 输出层的训练

本文隐含层的输出响应采用了高斯核函数 $k(x) = \exp\left(\frac{-\|\tilde{x} - \tilde{x}_0\|}{2\sigma^2}\right)$ 。同时,采用了 LMS 算法对输出层的权值进行训练。LMS 训练算法如下:

1) 设定期望响应: $\mathbf{d} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_m \end{bmatrix}$;

2) 计算隐含层输出响应:

$$k_1(x) = \exp\left(\frac{-\|x - x_{c1}\|}{2\delta_1^2}\right)$$

$$k_2(x) = \exp\left(\frac{-\|x - x_{c2}\|}{2\delta_2^2}\right)$$

\vdots

$$k_n(x) = \exp\left(\frac{-\|x - x_{cn}\|}{2\delta_n^2}\right)$$

3) 初始化权值系数: $w_{ij} \in (-1, 1)$ 和总的训练次数 z ;

4) 计算输出层响应:

$$\begin{bmatrix} \omega_{11} & \omega_{12} & \cdots & \omega_{1n} \\ \omega_{21} & \omega_{22} & \cdots & \omega_{2n} \\ \vdots & \vdots & & \vdots \\ \omega_{m1} & \omega_{m2} & \cdots & \omega_{mn} \end{bmatrix} \begin{bmatrix} k_1(x) \\ k_2(x) \\ \vdots \\ k_n(x) \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix};$$

$$5) \text{ 计算误差向量: } \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} = \begin{bmatrix} y_1 - d_1 \\ y_2 - d_2 \\ \vdots \\ y_m - d_m \end{bmatrix};$$

6) 修正权值:

$$\mathbf{W}(k+1) = \mathbf{W}(k) - \mu \begin{bmatrix} y_1 - d_1 \\ y_2 - d_2 \\ \vdots \\ y_m - d_m \end{bmatrix} \begin{bmatrix} k_1(x) & \cdots & k_n(x) \end{bmatrix};$$

7) 计算误差函数:

$$E(\omega) = \sum_{(x_p, d_p) \in TS} [d_p - f(x_p, \omega)]^2;$$

8) 若训练次数大于总的训练次数 z , 则退出; 否则, 转 4)。

4 仿真结果与分析

基于 Labview 平台, 通过对 {BPSK、QPSK、8PSK} 信号特征向量的提取和分类器的设计实现了 MPSK 信号子类识别, 并对本文分类器设计方法与传统判决数分类器设计方法和随机确定中心点 RBFNN 分类器设计方法进行了分析比较。其中, 仿真信号的规格为: 码元速率 $R_s = 1000$ Hz, 采样频率 $f_s = 16000$ Hz, 脉冲成型滤波器采用滚降系数为 0.5 的升余弦函数。

在 10 dB 的情况下对 {BPSK、QPSK、8PSK} 进行 10000 次的仿真, 提取出 10000 个特征参数向量 F_x 。其中, 8000 个特征向量用于训练, 2000 个特征向量用于识别率统计。在隐含层节点数相同的情况下, 分别对本文采用的减法聚类算法与随机确定中心点法的收敛性能进行了比较。均方误差训练曲线如图 2。




图 2 均方误差训练曲线

另外, 对 {BPSK、QPSK、8PSK} 分别在 5 dB、8 dB、10 dB、15 dB、20 dB 条件下提取 10000 个特征向量, 并对其中 2000 个特征向量用于分别采用本文算法和传统判决树方法进行了识别率统计, 得到的统计结果如表 2 和 3。

从图 2 可以明显看出本文算法比随机确定中心点法收敛后均方误差更小, 表明实际输出与期望响应距离更近, 从而在

判决输出的过程中能够有效提高正确识别率。另外, 随着接收信号信噪比的降低, 不同信号调制类型的特征参量差异变小。由于传统判决树分类器设计方法在判决输出存在误判级联影响, 而本文分类器设计方法综合考虑了所有特征参量, 能够在多维空间内寻找最佳分类面。从表 2 和 3 的统计结果看出, 在接收信号信噪比小于 10 dB 的情况下, 采用本文分类器设计方法要比传统判决树分类器的正确识别率要高。

表 2 本文算法 MPSK 正确识别率

信噪比/ dB	正确识别率/%			总识别 率/%
	BPSK	QPSK	8PSK	
5	80.15	77.14	97.67	84.75
8	100.00	96.85	100.00	99.00
10	100.00	100.00	100.00	100.00
15	100.00	100.00	100.00	100.00
20	100.00	100.00	100.00	100.00

表 3 传统判决树分类器设计方法 MPSK 正确识别率

信噪比/ dB	正确识别率/%			总识别 率/%
	BPSK	QPSK	8PSK	
5	62.90	71.10	83.90	72.75
8	96.90	100.00	100.00	99.00
10	96.90	100.00	100.00	99.00
15	100.00	100.00	100.00	100.00
20	100.00	100.00	100.00	100.00

5 结语

本文提出了一种应用减法聚类算法和 LMS 算法相结合的 RBF 神经网络分类器设计方法。在隐含层中心点数相同的情况下, 本文采用的减法聚类算法比随机确定中心点法的稳态收敛均方误差要小, 从而有效提高了接收信号的正确识别率。此外, 该算法能够实现对隐含层和输出层的自适应训练, 有效避免了传统 RBF 神经网络分类器设计方法隐含层训练的经验性、盲目性、随机性的缺点。同时, 与传统的判决树分类器设计方法相比, 该方法能在相同特征参量的情况下, 综合考虑所有特征参量, 有效提高正确识别率。仿真结果验证了该算法的有效性。

参考文献:

- [1] SWAMI A, SADLER B M. Hierarchical digital modulation classification using cumulants[J]. IEEE Transactions on Communications, 2000, 48(3): 416-419.
- [2] EBRAHIMZADEH A, SEYEDIN S A, DEGHAN M. Digital-signal-type identification using an efficient identifier[J]. EURASIP Journal on Advances in Signal Processing, 2007, 2007(1): 63-63.
- [3] 李霞, 吴楚, 高立辉. 应用 ANN 的数字信号调制模式识别的特征矢量分析[J]. 电路与系统学报, 2005, 10(3): 99-103.
- [4] HAYKIN S. Neural Networks: A Comprehensive Foundation[M]. 2nd ed. Bering: Tsinghua University Press, 2001: 298-304.
- [5] 高立辉. 人工神经网络应用于通信信号数字调制方式自动识别的研究与实现[D]. 郑州: 信息工程大学信息工程学院, 2005.
- [6] 陈卫东. 数字通信信号调制识别算法研究[D]. 西安: 西安电子科技大学, 2001.
- [7] 叶健, 吴月娴, 葛临东. 基于高效自适应聚类算法的调制识别研究[J]. 计算机工程与设计, 2007, 28(3): 506-508.
- [8] 贺涛. 基于改进 RBFN 的信号调制识别方法[J]. 信号处理, 2006, 22(4): 69-72.