

一种改进的 RBF 神经网络 DOA 估计方法

巫军卫, 张 旻, 钟子发

(解放军电子工程学院信息工程系安徽省电子制约技术重点实验室, 合肥 230037)

摘 要: 提出一种优化径向基函数神经网络来波方位(DOA)估计模型结构和参数的方法。利用误差准则函数的收敛性, 合理确定模型的隐层神经元数目, 根据阵列信号相位差特征的空间分布特点, 选择具有代表性的隐层神经元的中心, 构建的 RBF 神经网络更能反映阵列的测向能力。相比于目前的径向基函数神经网络测向模型的构建方法, 改进的 DOA 估计模型具有更好的泛化性能, 能够提高测向精度。实验结果验证了该方法的有效性。

关键词: 来波方位; 径向基函数神经网络; 误差准则函数; 隐层神经元; 初始中心

Improved DOA Estimation Method for RBF Neural Network

WU Jun-wei, ZHANG Min, ZHONG Zi-fa

(Anhui Province Key Laboratory of Electronic Restriction, Department of Information Engineering,
Electronic Engineering Institute of PLA, Hefei 230037, China)

【Abstract】 A novel algorithm for optimizing the structure and parameters of Direction of Arrival(DOA) estimation model based on radial basis function neural network is presented. By using the astringency of error criteria function, the number of hidden neurons can be decided reasonably, according to the distribution of signal phase difference between the antenna array, the representative hidden neuron centers can be selected. By this way, the constructed RBF model can be represented the direction finding capacity of the antenna array. Compared with the other Radial Basis Function(RBF) methods, the proposed model has the features of more generalization and accuracy DOA estimation. Experimental results show the effectiveness of the proposed approach.

【Key words】 direction of arrival wave; Radial Basis Function(RBF) neural network; error criteria function; hidden neuron; initial center

DOI: 10.3969/j.issn.1000-3428.2011.17.052

1 概述

来波方位(Direction of Arrival, DOA)估计在通信、雷达、声纳等方面的应用越来越广泛^[1], 然而在现代复杂电磁信号环境下, 传统的干涉仪、Music 等测向技术很难满足高精度、高分辨率、实时快速测向等要求。随着智能信息技术的发展, 研究通过海量样本学习解决来波方位估计的软计算方法, 所构建的 DOA 估计模型不仅时效性好, 而且利用实际采集的训练样本构建模型, 可以将噪声、信噪比、信号模型、传输通道等因素考虑进去, 有着良好的环境适应性^[2]。径向基函数神经网络因其非线性逼近能力强、收敛速度快以及全局收敛等优点, 被广泛应用于 DOA 估计^[3-5]。但是, 现有的方法重点在于探讨利用径向基(Radial Basis Function, RBF)神经网络对固定频段信号进行来波方位估计的有效性和可行性上^[3-4], 并没有深入研究神经网络测向模型的网络结构和参数对 DOA 估计精度的影响等问题。就目前的神经网络测向模型的构建方法而言, 隐层神经元数目、隐层中心的选择主要依靠经验进行多次尝试^[3-4], 由于训练样本的复杂性和海量特性, 该方法几乎无法实现对宽频段 DOA 估计模型的构建。为此, 本文提出一种优化 RBF 测向模型网络结构和参数的方法。

2 基于 RBF 神经网络的 DOA 估计模型

实现来波方位估计, 可以看作是完成从方位特征到来波方位的一个复杂的非线性映射。本文利用均匀圆阵列建立基于 RBF 神经网络的 DOA 估计模型。考虑一个远场的窄带信号 $s(t)$ 入射到 M 元阵列, 第 l 个阵元的接收信号为:

$$x_l(t) = g_l S(t - \tau_l) + n_l(t), \quad l = 1, 2, \dots, M \quad (1)$$

其中, g_l 为第 l 个阵元对信号的增益; $n_l(t)$ 是第 l 个阵元接收到的噪声; τ_l 为第 l 个阵元相对于参考点的延迟, 由均匀圆阵列的特性和电波传播的性质得到天线阵元间相位差为:

$$\varphi_{li} = \frac{4\pi R f}{q} \sin\left(\frac{\pi(l+i-2)}{M} - \theta\right) \sin\left(\frac{\pi(i-l)}{M}\right) \quad (2)$$
$$l = 1, 2, \dots, M; i = 1, 2, \dots, M$$

其中, R 为圆阵列的半径; f 为信号的频率; q 为光速。从式(2)可看出, 天线阵元间的相位差、频率和来波方位角存在一种映射关系: $f, \theta \rightarrow \varphi$ 。利用 RBF 神经网络可实现从相位差特征信息 φ 到来波方位角 θ 的映射, 输入输出映射关系为:

$$\theta_k = \sum_{i=1}^c w_i^k h(\|\varphi - x(i)\|^2), \quad k = 1, 2, \dots, m \quad (3)$$

其中, w_i^k 是输出层第 k 个输出与隐层第 i 个神经元之间的连接权重。一般选用高斯函数作为基函数, 则式(3)表达为:

$$\theta_k = \sum_{i=1}^c w_i^k e^{-\frac{\|\varphi - x(i)\|^2}{\sigma^2}}, \quad k = 1, 2, \dots, m \quad (4)$$

其中, c 是 RBF 网络的隐层神经元个数; $x(i)(i = 1, 2, \dots, c)$ 为基函数的中心; σ^2 为高斯函数的宽度系数。

在实际应用中, 以五元圆阵列为例, 需要对原始的 $0^\circ \sim 360^\circ$ 相位差进行预处理, 消除神经网络的输出从 $360^\circ \sim 0^\circ$ 不连

基金项目: 国家自然科学基金资助项目(60972161); 国家部委预研基金资助项目

作者简介: 巫军卫(1987—), 男, 硕士研究生, 主研方向: 智能测向, 神经网络; 张 旻, 教授、博士; 钟子发, 教授、博士生导师

收稿日期: 2011-02-25 **E-mail:** wujunwei1987611@163.com

续转换造成的逼近误差。因此,本文中模型输入层的输入为 $[\cos(\varphi_{ij}), \sin(\varphi_{ij})]$, $(i, j=1, 2, \dots, 5, i \neq j)$, 有 10 个输入层节点, 模型的期望输出为 $[\cos(\theta), \sin(\theta)]$, 有 2 个输出层节点。

3 优化 DOA 估计模型的构建

3.1 隐层神经元数目的确定

隐层神经元的基函数具有径向对称性, 且隐层中心被定义为网络输入层到隐层的连接权向量, 因此, 隐层对于训练样本有一个聚类的作用。其中, 隐层中心为类均值, 隐层神经元的个数代表聚类的类数, 合理的隐层神经元数目应该是训练样本在空间的正确划分, 即合理的聚类个数^[6]。

本文引入误差准则函数的概念, 利用误差准则函数的收敛性, 确定训练样本在空间的正确划分, 即合理的聚类个数, 从而确定合理的隐层神经元的数目。

假设所有训练样本可以划分为 c 类, 每一类看作一个样本集合 W_j , z_j 为类 j 的中心, x_i 为 W_j 类中的第 i 个训练样本, 误差准则函数 J 定义为: 所有样本集合中的样本到其中心的欧氏距离之和。

$$J = \sum_{j=1}^c \sum_{x_i \in W_j} \|x_i - z_j\|^2, \quad j=1, 2, \dots, c \quad (5)$$

对于一个给定的预分类数 c , 随机选择 c 个训练样本作为初始中心 $z_i (i=1, 2, \dots, c)$, 将所有的训练样本逐个按照最小欧式距离划分给 c 个样本集合中的某一个集合, 计算新的样本集合 W'_i 的中心:

$$z'_j = \frac{1}{n_j} \sum_{x_i \in W'_j} x_i, \quad j=1, 2, \dots, c \quad (6)$$

其中, n_j 为 W'_j 样本集合中所含训练样本的个数, 经过数次的反复迭代, 当样本集合的中心不再变化时, 即:

$$z'_j = z_j \quad (7)$$

计算误差准则函数 J 的值, 不同的 c 值对应不同的 J 值。

分析误差准则函数 J 的收敛性, 发现随着 c 的增加, 误差准则函数 J 单调减少。因为在 c 增加的过程中, 总会出现使本来聚集在一起的训练样本再次被划分开的情况。当 c 增加到一定数量时, J 的减少速率将变缓, 作一条 J - c 曲线, 误差准则函数 J 变化比较平缓的区域就是训练样本的合理类数的区间范围, 也就是最佳隐层神经元数目的区间范围, 因为一旦神经元数目选取得过多, 增加了网络复杂性的同时也会使泛化性能下降, 从而影响到测向精度。

利用上述方法, 对仿真产生的 1 800 个训练样本进行实验。从图 1 可以看出, 当隐层神经元数目从 100 增加到 160 时, 误差函数值急剧下降。随后, 随着 c 的增加, 误差函数值减小的速度变得缓慢, 当 c 增加到 180~200 时, 误差函数值几乎不再改变, 考虑到网络结构的复杂性和泛化性能, 选择的隐层神经元的数目在 180~200 之间是比较合理的。

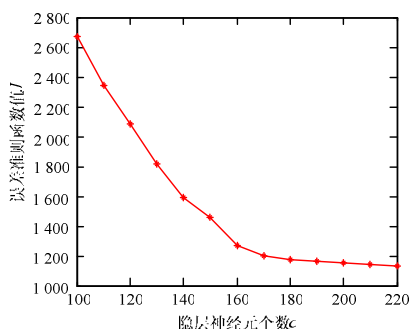


图 1 J-c 曲线

3.2 隐层神经元中心的优化选择

一般情况下, 对于给定的聚类个数 c , 随机选择 c 个训练样本作为初始中心, 按照欧氏距离的大小进行归类, 经过反复迭代后, 产生不再变化的中心 $z_j (j=1, 2, \dots, c)$ 。此时可以将 z_j 作为各个隐层神经元的中心^[3-4], 但是采用随机选择初始中心的方法没有考虑到样本的实际分布情况, 有可能使算法陷入局部最优, 无法获得好的隐层中心, 从而影响到模型的测向精度。因此, 需要对初始中心的选择方法进行改进。

根据均匀圆阵列的特性和电波传播的性质, 相位差样本特征的空间分布存在以下特点: (1)特征随频率 f 的变化呈现出近似周期性分布; 在较窄的频段范围内, 不同频率 f 在相同方位 θ 上有相似的样本特征 φ ; (2)当超出一定的频段范围时, 即使在相同方位 θ 上, 对应的样本特征 φ 差异也较大; (3)在同一频率 f 上, 相邻的若干个方位对应的样本特征 φ 的相似性较强。

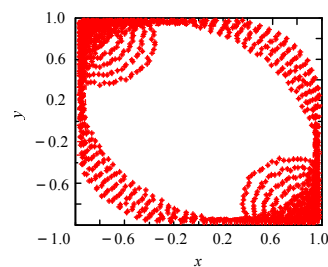
依据样本特征随频率和来波方位变化分布的特点, 本文提出一种选择初始中心的启发式方法。具体方法步骤如下:

步骤 1 产生宽频段、全方位的训练样本集, 每一个频率点 f 对应的全方位训练样本的数量为 H 。

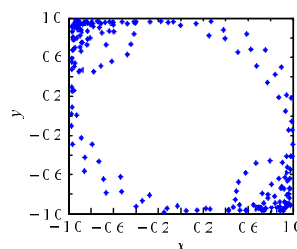
步骤 2 在所有样本中取 t 段数据, $s = \{s_1, s_2, \dots, s_t\}$, s_i 代表某一频率点对应的全方位训练样本, 数量为 H , t 段样本总量为 $U = t \times H$ 。

步骤 3 对 U 进行划分, 将 U 个训练样本按频率和来波方位的先后顺序均等地分给 c 个样本集合 $W_i (i=1, 2, \dots, c)$, 计算每个样本集合 W_i 的中心, 并将其作为初始中心。步骤 2 中 t 的选择原则是根据隐层神经元数目 c 的大小, 按频率分布进行选择, 所选频率的分布尽量广泛。

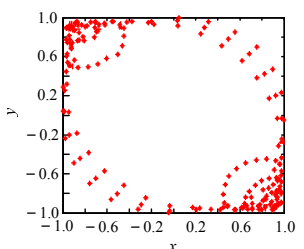
图 2(b)和图 2(c)所示的是利用 2 种不同的方法得到的隐层中心, 由于本文的样本特征是 10 维的数据, 在 10 维的超平面上无法直观显示启发式方法的有效性, 因此, 在最终的隐层中心确定以后, 选择 10 维样本数据中任意的 2 维数据, 进行对照比较。图 2(b)中的初始中心任意选择的, 图 2(c)是利用启发式方法选择初始中心, 再获得的隐层中心, 可以看出, 图 2(c)中的隐层中心更能反映图 2(a)中实际二维样本特征的空间分布规律。



(a) 二维样本特征的空间分布



(b) 二维隐层中心的空间分布 1



(c) 二维隐层中心的空间分布 2

图 2 二维样本特征与隐层中心的空间分布

4 实验及性能分析

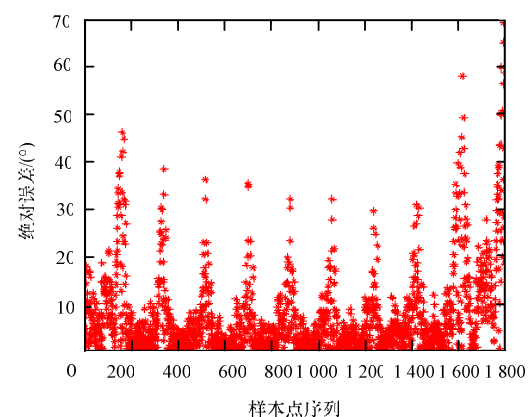
4.1 实验环境

天线阵列采用均匀 5 元圆阵, 半径 0.75 m, 信噪比为 5 dB~20 dB。产生样本: 频率 100 MHz~190 MHz, 步进 10 MHz, 角度 0°~360°, 步进 1°, 共 3 600 个样本。在已产生的样本中每间隔 1° 选择一个样本作为训练样本, 共产生 1 800 个训练样本, 另外的 1 800 个样本作为测试样本。利用 VC++ 编程实现了上述构建径向基函数神经网络测向模型的算法。

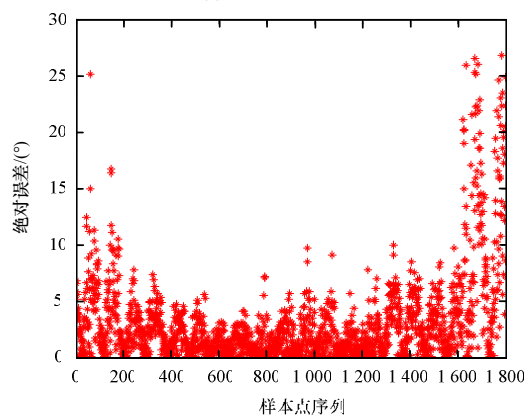
4.2 实验结果

实验 1 不同隐层神经元数目对模型测向精度的影响

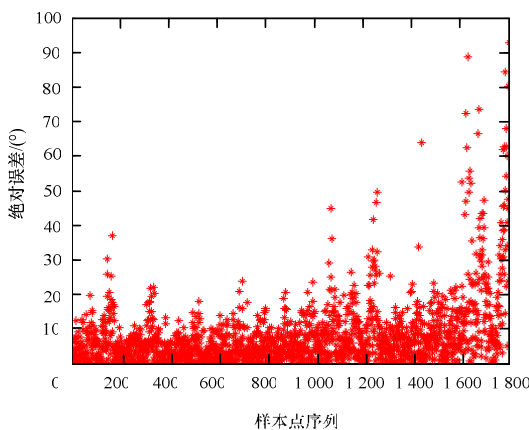
比较隐层神经元个数不同时模型的测向精度。分别选择隐层神经元数目为 100、180、300 构建测向模型。图 3(a)~图 3(c)给出了 3 种模型来波方位估计的绝对误差。



(a) 隐层数为 100



(b) 隐层数为 180



(c) 隐层数为 300

图 3 来波方位估计的绝对误差 1

从图 3 可以看出, 隐层神经元数目为 180 时, 构建的模型测向精度较高, 平均误差为 2.87°; 当隐层神经元数目取值为 100 和 300 时, 构建的模型测向精度有所下降, 平均误差分别为 5.986 7° 和 6.751 3°。

隐层神经元数目选择的过多或者过少都会影响到模型的测向精度, 利用 J - c 曲线图确定隐层神经元个数的合理范围, 可以减少隐层神经元数目选择的盲目性, 提高模型的测向精度。

实验 2 不同初始中心对模型测向精度的影响

在相同隐层神经元数目条件下, 利用随机选择初始中心的方法构建模型获得的估计结果和误差, 由于没有考虑到样本特征的实际空间分布, 获得的隐层中心代表性不是很强, 最大估计误差达到了 28° 左右。

利用启发式方法获得初始中心, 优化了模型的隐层中心, 测向精度明显提高, 如图 4 所示, 平均误差降低至 0.347 4°。启发式选择初始中心的方法对提高模型的测向精度是有效的。

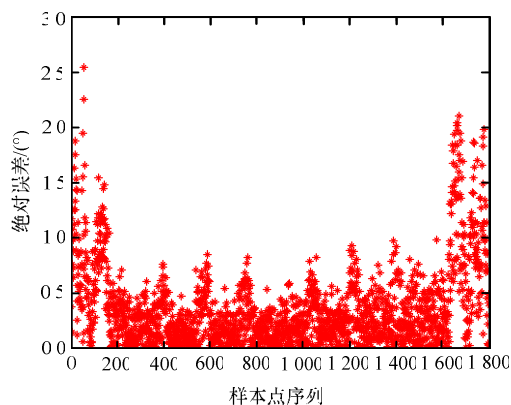


图 4 来波方位估计的绝对误差 2

5 结束语

本文提出了一种优化径向基函数神经网络测向模型结构和参数的方法。对训练样本进行预处理, 降低逼近误差; 引入误差准则函数, 确定合理的隐层神经元数目; 根据阵列信号相位差特征的空间分布特点, 利用启发式方法选择初始中心, 进而获得更具代表性的隐层中心; 通过实验验证了所提方法的有效性。

参考文献

- [1] 王 进, 赵拥军, 王志刚. 低信噪比条件下的高分辨 DOA 估计算法[J]. 计算机工程, 2009, 35(3): 96-98.
- [2] 安 冬, 王守觉. 基于仿生模式识别的 DOA 估计方法[J]. 电子与信息学报, 2004, 26(9): 1468-1472.
- [3] Wang Min, Yang Shuyuan, Wu Shunjun, et al. A RBFNN Approach for DOA Estimation of Ultra Wideband Antenna Array[J]. Neuro Computing, 2008, 71(4-6): 631-640.
- [4] 于 斌, 尹成友, 黄 冶. 阵列误差影响下的神经网络波达方向估计[J]. 微波学报, 2007, 23(6): 21-25.
- [5] 张 旻, 李鹏飞. 基于分层神经网络的宽频段 DOA 估计方法[J]. 电子与信息学报, 2009, 31(9): 2118-2122.
- [6] Narendra K G. Application of a Radial Basis Function(RBF) Neural Network for Fault Diagnosis in HVDC System[J]. IEEE Trans. on Power Systems, 1998, 13(1): 177-183.

编辑 顾逸斐