

## 基于互相关函数相角特征的 RBF 神经网络来波方位估计

张 旻<sup>①②</sup> 李鹏飞<sup>①②</sup>

<sup>①</sup>(合肥电子工程学院 309 研究室 合肥 230037)

<sup>②</sup>(安徽省电子制约技术重点实验室 合肥 230037)

**摘 要:** 有效的方位特征获取对构建智能来波方位估计模型具有十分重要的意义。该文在分析阵列接收信号相关函数的基础上,首次提出利用相邻阵元信号互相关函数的相角作为来波方位特征。与常用的协方差矩阵上三角特征相比,剔除了与来波方位无关的幅度信息和冗余的方位特征信息,在不损失有效方位信息的基础上使特征维数得到极大地降低。实验结果表明,利用相角特征构建的 RBF 神经网络的结构更简洁,泛化性能更好,来波方位估计精度高,实时性好,具有广阔的工程应用价值。

**关键词:** 信号处理; DOA 估计; 协方差矩阵; 相角特征; 径向基神经网络

中图分类号: TN911.23

文献标识码: A

文章编号: 1009-5896(2009)12-2926-05

## Direction of Arrival Estimation Approach Based on Phase Angle Feature of Correlation Function Using RBF Neural Networks

Zhang Min<sup>①②</sup> Li Peng-fei<sup>①②</sup>

<sup>①</sup>(Division 309, Hefei Electronic Engineering Institute, Hefei 230037, China)

<sup>②</sup>(Anhui Electronic Restricting Technique Key Laboratory, Hefei 230037, China)

**Abstract:** Effective feature extraction is very important when building the smart DOA estimation model. Based on analyzing the correlation function of the array signal, this paper firstly presents using the angles of contiguous array signal's correlation function for DOA estimation purpose instead of common used upper triangular half of the covariance matrix, which eliminates the irrelevant magnitude information and redundant direction characteristic. Therefore the feature dimension is largely reduced without losing any DOA information. Experimental results show that the performance of RBF neural network using proposed Phase-feature is superior to the common used upper triangular half of the covariance matrix in terms of neural network size, generalization, estimation precision and real-time performance, so it has a broad application value.

**Key words:** Signal processing; DOA estimation; Covariance matrix; Phase angle figures; RBF neural network

### 1 引言

在现代电子战信号环境中,由于信号密度大,信号形式复杂,使得电子侦察中的信号处理任务越来越困难。对无线电测向提出了高精度、高分辨率、实时快速等方面的要求。传统的 MUSIC 法、ESPRIT 法等算法运算量大,无法实时实现,同时对实际应用环境的适应性差,达不到要求的性能指标,使得这些理论算法大都停留在实验室仿真上<sup>[1]</sup>。一种新的采用智能学习、“软建模”进行 DOA 估计的方法得到了国内外专家的广泛关注<sup>[1-11]</sup>。其优点在于建模过程是采用训练样本构造非线性模型,而不是精确的数学方程式,在实际情况下采集的训练样本可以将噪声、信噪比、信号模型、传输通道等

因素考虑进去,同时采用建模的方法不需进行特征值分解、谱峰搜索、且计算可以并行快速实现,从而有望应用于实际工程<sup>[1]</sup>。文献[1-11]采用神经网络对来波方位进行估计,研究结果显示基于神经网络的 DOA 估计算法在测向速度、精度和对低信噪比、阵列误差、天线互耦的适应性等方面明显优于传统的 MUSIC 方法。

利用神经网络等智能计算方法对来波方位进行估计时,特征的选择直接影响到模型的构建和估计的性能。常用的特征有:相位差、协方差矩阵和特征向量等<sup>[8]</sup>。其中相位差的提取受噪声、信号调制样式影响较大而难以实现高精度的提取,特征向量需要特征值分解时效性较差,因此目前应用较多的是阵列接收信号的协方差矩阵特征。本文通过理论分析表明协方差矩阵作为输入特征,含有对来波方位无关的幅度信息和冗余特征,造成特征维数过多,

网络结构复杂等问题。本文利用相邻阵元接收信号的互相关函数的相角作为输入特征(下文称相角特征),构建模型对来波方位进行估计。与协方差矩阵的上三角特征相比,消除了无关的幅度信息和冗余特征,特征维数得到了极大地降低,而包含的有效信息并没有减少。与相位差特征相比,由于互相关函数对噪声的抑制作用对噪声的适应性较好,同时还回避了相位差的高精度提取等问题,因此特征的鲁棒性能较好。利用本文提出的相角特征训练神经网络,实现了简化网络结构,提高训练速度,增强泛化能力的目的。理论分析和实验结果都验证了本文方法的优越性。

## 2 相角特征的提取

假设远场信号入射到半径为  $R$  的  $M$  元均匀圆阵列天线上,方位角为  $\theta$ ,  $t$  时刻第  $l$  个阵元的接收信号为

$$x_l(t) = s(t)e^{j\xi \cos(\theta - \gamma_l)} + n_l(t), \quad l = 1, 2, \dots, M \quad (1)$$

式中  $\xi = (2\pi R/\lambda)$ ,  $\gamma_l = 2\pi l/M$ ,  $s(t)$  为接收信号,  $n_l(t)$  表示均值为 0, 方差为  $\delta^2$  的加性高斯白噪声。 $M$  个阵元在时刻  $t$  接收到的信号写成一个矢量,可表示为

$$\mathbf{X}(t) = \mathbf{A}(\theta)\mathbf{S}(t) + \mathbf{N}(t) \quad (2)$$

其中  $\mathbf{A}(\theta)$  是方向矩阵,噪声  $\mathbf{N}(t)$  是独立于信号的白高斯过程。可见空间信号的方位信息全部包含在阵列接收信号矢量或阵列协方差矩阵式(3)中:

$$\begin{aligned} \mathbf{R} &= E[\mathbf{X}(t)\mathbf{X}^H(t)] \\ &= AE[\mathbf{S}(t)\mathbf{S}^H(t)]\mathbf{A}^H + E[\mathbf{N}(t)\mathbf{N}^H(t)] \end{aligned} \quad (3)$$

文献[1-8]都是利用式(3)构造输入特征。对于  $M$  元天线阵列,协方差矩阵有  $M^2$  个元素:

$$\begin{aligned} \mathbf{r} &= [r_{11} \cdots r_{1M} \cdots r_{M1} \cdots r_{MM}] \\ &= [a_{11} + jb_{11} \cdots a_{1M} + jb_{1M} \cdots a_{M1} \\ &\quad + jb_{M1} \cdots a_{MM} + jb_{MM}] \end{aligned} \quad (4)$$

式(4)的矢量维数为  $M^2$ 。由于协方差矩阵的对称性和对角线元素不含方位信息,因此现有的研究多是取协方差矩阵的上三角部分(不含对角线元素),矢量特征变为

$$\begin{aligned} \mathbf{r}' &= [r_{12} \cdots r_{1M} \cdots r_{23} \cdots r_{(M-1)M}] \\ &= [a_{12} + jb_{12} \cdots a_{1M} + jb_{1M} \cdots a_{23} \\ &\quad + jb_{23} \cdots a_{(M-1)M} + jb_{(M-1)M}] \end{aligned} \quad (5)$$

考虑式(5)中的矢量是复数,因此实际建模过程中需要将复数分为实部和虚部两部分,用式(5)的结果作为 DOA 估计模型输入特征,维数为  $M(M-1)$ 。即便如此特征的维数仍然很多。以 9 元阵列为例,输入特征维数是 72 维。由模式识别的相关理论可知

过多的维数对模型的构建存在以下问题:(1)随着维数增加,数据在它所占的空间中越来越稀疏,可能意味着没有足够的对象来创建模型,可靠地将所有可能的对象指派到一个类。(2)维数多意味着样本数据复杂性增大,当训练样本海量时,模型的构建与处理就会变得很困难。目前特征维数过多是影响宽频段智能 DOA 估计的主要因素之一,因此需要对特征进行优化处理。

对式(3)进一步分析可知,第  $l$  个阵元接收信号和第  $k$  个阵元接收信号之间的互相关函数为

$$\begin{aligned} R_{lk}(\tau) &= E\{x_l(t + \tau/2)x_k^*(t - \tau/2)\} \\ &= E\{s(t + \tau/2)s^*(t - \tau/2)e^{j\xi \cos(\theta - \gamma_l)} \\ &\quad \cdot e^{-j\xi \cos(\theta - \gamma_k)}\} + E\{n_l(t + \tau/2)n_k^*(t - \tau/2)\} \end{aligned} \quad (6)$$

由于  $n_l(t)$  为高斯白噪声,  $E\{n_l(t + \tau/2)n_k^*(t - \tau/2)\} = 0$ , 所以

$$R_{lk}(\tau) = R_{ss}(\tau)e^{j\xi[\cos(\theta - \gamma_l) - \cos(\theta - \gamma_k)]} \quad (7)$$

$R_{ss}(\tau)$  为信号的自相关函数,与来波方位无关,从式(7)可以看出来波信号的方位信息全部包含在相角之中,与  $R_{ss}(\tau)$  无关。当  $\tau=0$  时,  $R_{lk}(0) = E\{x_l(t)x_k^*(t)\}$  就是式(3)中的对应元素。可见目前常用的协方差矩阵上三角特征将其无关的幅度信息引入进去。而幅度受信号发射功率、噪声等因素影响较大,需要剔除。对(5)式进行处理:

$$\begin{aligned} \mathbf{r}' &= [\gamma_{12}e^{j\psi_{12}} \cdots \gamma_{1M}e^{j\psi_{1M}} \cdots \gamma_{23}e^{j\psi_{23}} \cdots \\ &\quad \gamma_{(M-1)M}e^{j\psi_{(M-1)M}}] \end{aligned} \quad (8)$$

提取式(8)中的相角:  $[\psi_{12} \cdots \psi_{1M} \cdots \psi_{23} \cdots \psi_{(M-1)M}]$  作为输入特征,这样就能获取只与来波方位相关的相角特征,维数压缩了一半。再由式(6)可知阵元  $l$  接收信号和阵元  $k$  接收信号之间的互相关函数的相角为

$$\psi_{lk} = \xi[\cos(\theta - \gamma_l) - \cos(\theta - \gamma_k)] \quad (9)$$

由式(9)易得

$$\psi_{li} = \psi_{lk} + \psi_{ki} \quad (10)$$

通过式(10)可以看出,对于  $M$  元天线阵列,只要知道了相邻阵元接收信号互相关函数的相角,就可以进行处理获取任意两个阵元接收信号互相关函数的相角了。这表明了提取的式(8)相角特征中还存有大量的冗余的方位特征信息可以进一步剔除。对于  $M$  元天线阵列,可以选择相邻阵列的互相关函数的相角作为来波方位特征:

$$\mathbf{X} = [\psi_{12}, \psi_{23}, \dots, \psi_{(M-1)M}, \psi_{M1}] \quad (11)$$

相邻天线阵列之间的相关函数的相角包含了来波方位的全部信息。以  $M$  元天线阵列为例与协方差矩阵的上三角特征相比,维数从  $M(M-1)$ , 降为  $M$ ,

极大地降低了输入的维数，从而降低了模型构建的复杂度，这对来波方位估计特别是宽频段的来波方位估计有很大的价值。

### 3 基于相角特征的 RBF 神经网络构建

RBF 神经网络具有输入层、隐层和输出层，结构如图 1 所示。输入层输入的是提取的方位特征信息。训练完成后 RBF 神经网络的输入输出映射关系为

$$\theta_k(X) = \sum_{i=1}^L w_i^k h(\|X - c(i)\|^2), \quad k = 1, 2, \dots, m \quad (12)$$




图 1 RBF 神经网络结构

$w_i^k$  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，则式(12)表达为

$$\theta_k(X) = \sum_{i=1}^L w_i^k e^{-\frac{\|X - c(i)\|^2}{\sigma^2}}, \quad k = 1, 2, \dots, m \quad (13)$$

这里  $L$  是 RBF 网络的隐层神经元数， $c(i)$  ( $i = 1, 2, \dots, L$ ) 为基函数的中心， $\sigma^2$  为高斯函数的宽度系数。

考虑到网络的复杂性，采用混合训练算法训练 RBF 神经网络，首先通过  $K$  均值聚类算法选择 RBF 网络的中心；然后采用最小二乘算法计算网络的隐层与输出层神经元之间的权值。算法步骤如下：

(1)根据公式(11)产生训练样本集  $\{(X_i, \theta(X_i))\}$ ,  $i = 1, 2, \dots, N$ ,  $X_i$  是输入特征,  $\theta(X_i)$  是 DOA 空间样本,  $N$  是样本数。

(2)将步骤(1)产生的训练样本集输入到网络中, 利用  $K$  均值聚类算法确定隐层神经元的中心  $\{C_1, C_2, \dots, C_J\}$ 。其中  $J$  是隐层神经元的个数, 神经元初始个数为 1, 当网络均方根误差不能满足训练目标时增加一个神经元。

(3)确定隐层神经元的宽度  $\delta = D / \sqrt{2J}$ 。其中  $D$  是隐层中心之间的最大距离。

(4)利用最小二乘法计算计算网络的隐层与输出层神经元之间的权值  $w_i$ ,  $i = 1, 2, \dots, J$ 。

(5)计算网络的输出。径向基函数选用的是高斯函数, 则网络的输出为

$$\theta(X) = \sum_{i=1}^J w_i e^{-\|X - c_i\|^2 / \sigma^2} \quad (14)$$

(6)计算输出的均方根误差。若满足训练目标则训练结束, 否则跳转到步骤(2)。

训练结束后, 神经网络就具有对来波方位估计的非线性能力。

### 4 仿真实验及分析

#### 实验 1 估计精度分析

天线阵列采用均匀 5 元圆阵, 半径 0.75 m。训练样本: 信噪比 10~20 dB, 频率 100 MHz~200 MHz, 步进 20 MHz, 角度 0~360°, 步进 10°, 共计 180 组; 测试样本: 在信噪比 10~20 dB 范围, 选择 123 MHz, 142 MHz, 173 MHz 和 196 MHz 4 个频率点, 每隔 1° 产生一个样本, 共计产生 1440 组测试样本。图 2 来波方位估计结果; 图 3 是估计的绝对误差曲线; 图 4 是不同信噪比(高斯白噪声)情况下的均方根误差。

从图 2 可以看出本文方法的估计结果基本上与真实值重合。从图 3 能更清楚的看出, 估计的绝对误差基本在 1° 度以内, 可以达到很高的估计精度。




图 2 来波方位估计结果




图 3 预测绝对误差




图 4 不同信噪比下的均方根误差

从图 4 看出随着在信噪比的增大预测精度逐步提高, 在较低的信噪比(负信噪比)时本文介绍方法的估计精度还是很高的。

实验 2 性能比较

在信噪比 10~20 dB, 频率 100 MHz~200 MHz, 角度在 0~360° 范围内, 分别按照频率步进 20 MHz, 角度步进 10°; 频率步进 10 MHz, 角度步进 5°; 频率步进 10 MHz, 角度步进 3° 产生 3 组训练样本, 第 1 组 180 个, 第 2 组 720 个, 第 3 组 1200 个。分别用这三组样本建立模型, 用实验 1 的测试样本检验模型性能。分别用本文提出的相角特征和文献[7]中协方差矩阵的上三角特征训练 RBF 神经网络模型。实验条件: P43.0 GHz CPU; 512 M 内存; Matlab7.0 开发平台。表 1 为网络性能的比较结果。

从表 1 中可以得到如下结论: (1)随着训练样本的增加网络的结构和训练时间急剧增加, 但和协方差矩阵上三角特征训练的神经网络相比, 用本文提出的相角训练的网络无论在网络结构和训练时间上都小的多, 当训练样本增加到 1200 个时, 协方差矩

表 1 网络性能比较

	训练样本数	RMS 测试误差 (°)	RMS 训练误差 (°)	隐节点数	训练时间 (s)	测试时间 (s)
相角特征	180	0.43	0.08	41	0.66	0.067
	720	0.56	0.13	203	27	0.250
	1200	0.48	0.11	303	53	0.530
协方差矩阵上三角特征	180	1.13	0.11	66	1.259	0.125
	720	1.04	0.12	368	111	0.750
	1200	1.01	0.12	754	1108	1.735




图 5 来波方位估计结果




图 6 估计的绝对误差

阵上三角特征训练网络的的时间是相角特征的 20 倍多; (2)本文提出的相角特征训练网络, 来波方位估计精度高于协方差矩阵训练的网络估计精度; (3)测试时间(表中的测试时间为 1440 次的总时间)上看神经网络法可以达到微秒量级比常规算法要快的多, 适合于实时测向。

实验 3 多目标信号来波方位估计

假设 2 个非相干信号入射到半径为 0.75 m 的均匀 5 元圆阵列天线上。训练阶段两个信号的间隔为依次为 15°, 30°, 45°, 60°, 75°, 105°, 120° 和 135°。以间隔为 15° 为例, 两个信号的角度依次为 (0°, 15°), (5°, 20°), ..., (355°, 10°)。图 5 是角度间隔 37° 时两个信号的估计结果, 图 6 是对应的绝对误差。图 7 是不同角度间隔下估计的均方根误差(每个角度间隔进行 50 次独立实验)。

由于神经网络的泛化能力, 可以学习获得训练阶段没有学习过的角度间隔。从图 5 和图 6 可以看出, 来波方位的估计值基本与理论值重合。从图 7 可以看出本为提出的特征建立模型, 虽然特征的维数得到了极大的降低, 但是和协方差的上三角特征相比网络的泛化性能并没降低, 也说明了本文提出特征的有效性。

5 结束语

本文利用相邻阵元接收信号的互相关函数的相角作为神经网络的输入特征。与协方差矩阵的上三角特征相比, 有效信息更直接, 同时消除了无关的幅度信息和冗余特征的影响, 降低了特征的维数。实验结果验证了该特征的有效性。无线电测向面临的是宽频段来波方位估计, 由于频段宽, 信号样式复杂, 智能测向面临的将是一个海量数据的学习问题。要使得构建的模型能够满足一个很宽的频段范围将是十分复杂的难题。采用本文提出的相角特征, 有效地减少输入特征的维数, 降低了模型构建的复

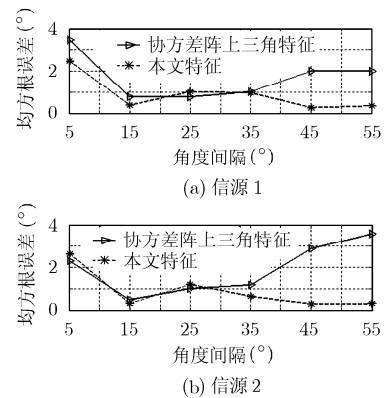


图 7 不同角度间隔下的均方根误差

杂度, 为宽频段来波方位估计创造了一定的条件, 下一步将能利用向相角特征展开对宽频段来波方位估计的研究。

### 参 考 文 献

- [1] 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.  
An Dong and Wang Shou-jue. A DOA estimation method based on biomimetic pattern recognition [J]. *Journal of Electronics & Information Technology*, 2004, 26(9): 1468-1472.
  - [2] Guo Wo, Qin T S, and Tang H, *et al.* Performance of RBF neural networks for array processing in impulsive noise environment [J]. *Digital Signal Processing*, 2008, 18(2): 168-178.
  - [3] Wang M, Yang S, and Wu S, *et al.* A RBFNN approach for DOA estimation of ultra wideband antenna array[J]. *Neurocomputing*. 2008, 71(4-6): 631-640.
  - [4] Vigneshwaran S, Sundararajan Narasimhan, and Saratchandran P. Direction of arrival (DOA) estimation under array sensor failures using a minimal resource allocation neural network[J]. *IEEE Transactions on Antennas and Propagation*, 2007, 55(2): 334-343.
  - [5] Dourado O D, Doria A D, and Da Mata W. Determination of multiple direction of arrival in antennas arrays with radial basis functions[J]. *Neurocomputing*, 2006, 70(1-3): 55-61.
  - [6] Kuwahra and Matsumoto. Experiments of direction finder by RBF neural network with post processing. *IEEE Electronic Letters*, 2005, 41(10): 24-25.
  - [7] 严颂华, 吴世才, 吴雄斌. 基于神经网络的高频地波雷达目标到达角估计[J]. 电子与信息学报, 2008, 30(2): 339-342.  
Yan Song-hua, Wu Shi-cai, and Wu Xiong-bin. DOA estimation based on neural network for HFGWR[J]. *Journal of Electronics & Information Technology*, 2008, 30(2): 339-342.
  - [8] 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.  
Yu Bin, Yin Cheng-you, and Huang Ye. Direction of arrival(DOA) estimation for an array with errors using RBF neural network [J]. *Journal of Microwaves*, 2007, 23(6): 21-25.
  - [9] 安冬, 王守觉. 基于仿生模式识别和 PCA/ICA 的 DOA 估计方法[J]. 电子学报, 2004, 32(9): 1448-1451.  
An Dong and Wang Shou-jue. A DOA estimation method based on biomimetic pattern recognition and PCA/ICA [J]. *Acta Electronica Sinica*, 2004, 32(9): 1448-1451.
  - [10] Shieh Ching-Sung and Lin Chin-Teng. Direction of arrival estimation based on phase differences using neural fuzzy network[J]. *IEEE Transactions on Antennas and Propagation*, 2000, 48(7): 1115-1123.
  - [11] 陈荆花, 易辉跃, 周希朗. 基于特征矢量输入的神经网络测向方法[J]. 上海交通大学学报, 2003, 37(3): 373-379.  
Chen Jing-hua, Yi Hui-yue, and Zhou Xi-lang. Direction of arrival estimation method with eigenvector based radial basis function neural network[J]. *Journal of Shanghai Jiao Tong University*, 2003, 37(3): 373-379.
- 张 旻: 男, 1966 年生, 博士, 教授, 从事通信信号处理、模式识别、计算智能等方向研究。
- 李鹏飞: 男, 1983 年生, 硕士生, 从事通信信号分析与智能信息处理方面的研究。