

基于神经网络的相干信源稳健 DOA 估计

钟东强, 何培宇, 喻伟闯

(四川大学电子信息学院, 成都 610065)

摘要: 目前基于神经网络的 DOA 估计主要是针对理想情况下的均匀线阵, 且信源非相干, 可估计的信源数较少。针对阵列误差和相干信源同时存在的问题, 在理想数据集中引入互耦误差、阵元幅度误差、阵元相位误差以及阵元位置误差, 并设计了一个多通道 CNN+DNN 网络和目标函数生成方法, 用于相干信源的稳健 DOA 估计。引用 B-band 互耦模型和相关误差模型合成阵列输出信号, 通过提取阵列输出信号的协方差矩阵的实部、虚部与相位角, 构建网络的输入信号。对理想条件下的 MUSIC 算法 DOA 估计结果进行拟合, 根据拟合公式生成多信源从不同角度入射时的空间谱, 作为网络的目标信号。使用相同的数据集对本文 DOA 估计网络与其它文献中的 DOA 估计网络进行训练和测试。结果显示, 在不同信噪比、不同误差大小以及不同信源数的情况下, 本网络的稳健性和解相干能力都更优。

关键词: DOA; 均匀线阵; 神经网络; 鲁棒性; 相干

中图分类号: TN911.23 文献标识码: A DOI: 10.19907/j.0490-6756.2023.023001

Robust DOA estimation of coherent sources based on neural network

ZHONG Dong-Qiang, HE Pei-Yu, YU Wei-Chuang

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Most neural network-based DOA estimation methods are designed for the uniform linear array with a few incident signals which are uncoherent under ideal situation. To tackle the case that the array is imperfect and its signals are coherent, this paper designs a multi-channel CNN-DNN network and an objective function generation by introducing the errors of mutual coupling, amplitude, phase, and location with coherent signals. The input signals of the proposed nerual network are constructed by extracting the real part, imaginary part and phase angle from the covariance matrix of the array output. The DOA estimation results of the MUSIC algorithm under ideal conditions are fitted and the fitting result is used to generate the target of the network. The DOA estimation networks proposed in this paper and other literature are trained and tested using the same data set. The results show that the robustness and decoherence ability of the proposed network are better in terms of different signal-to-noise ratios, array errors and numbers of signal sources, compared to the previous neural network-based DOA methods.

Keywords: DOA; Linear uniform array; CNN; Robustness; Coher

收稿日期: 2022-04-21

基金项目: 国家自然科学基金联合基金项目(U1733109)

作者简介: 钟东强(1996—), 男, 硕士研究生, 研究方向为阵列信号处理. E-mail: zhongdq937@163.com

通讯作者: 何培宇. E-mail: hpsbsy@163.com

1 引言

在阵列信号处理领域中,波达方向(Direction of Arrival, DOA)估计是重要的组成部分之一。为了更快地完成空域滤波,波束成形等任务,阵列需要信号的DOA信息作为先验信息。DOA在一些目标定位,海底地形勘察应用中扮演着重要角色,如应用于雷达和声纳中。随着科技进步与应用的扩展,阵列信号处理也已经融入到我们的生活中。4G与5G技术中,大量使用多天线和波束成形技术,通信基站信号波束的指向需要DOA为其提供方向,基站对接收信号进行空域滤波也需要信号的DOA信息。在各种关于阵列信号的研究中,涌现了很多不同种类的DOA估计算法,其中较为经典的便是基于特征分解的方法。

多重信号分类(Multiple Signal Classification, MUSIC)算法和旋转不变技术的信号参数估计(Estimating Signal Parameters via Rotational Invariance Techniques, ESPRIT)算法是两种经典的基于特征分解的DOA估计算法。特征分解后,MUSIC算法通过划分信号子空间与噪声子空间,利用信号子空间与噪声子空间正交的特点,对不同入射方向的导向矢量进行扫描,可以实现对多个信源的超分辨DOA估计^[1]。ESPRIT算法利用信号子空间的旋转不变特性,不用进行空间扫描也可以实现超分辨DOA估计^[2]。但是,这些算法都是在一些理想条件下进行,需要阵列模型作为先验信息,受互耦等因素影响大,鲁棒性不高^[3],并且无法估计相干信号。使用空间平滑算法可以有效地解决基于上述两种算法不能解相干的问题,但缺点是可估计信源数目会减半^[4]。

近年来,随着计算机性能的提升和神经网络的发展,出现了很多基于机器学习^[5]与神经网络的DOA估计算法。相较于传统方法,基于神经网络的方法不需要阵列模型作为先验信息,具有更高的鲁棒性和普适性。模型训练完成后,DOA估计的过程中只存在线性运算,其运算速度完全可以做到实时估计。当需要扩展网络模型的使用场景时,利用迁移学习,可以快速地对模型进行扩展,从而适应新的阵列模型。常见的DOA估计算法主要包括:深度神经网络(Deep Neural Networks, DNN)^[6-11]、卷积网络(Convolutional Neural Network, CNN)^[12-14]、CNN级联循环神经网络(Recurrent Neural Network, RNN)的CNN-RNN网

络^[15-19]。Liu等^[9]用信号协方差矩阵的上三角信号作为输入信号,使用DNN自编码器对输入进行特征提取,利用迁移学习训练多通道DNN网络。在信源数为2时,完成了弱互耦下的DOA估计。利用残差网络(Residual Networks, ResNet)可以训练更深层神经网络的特点,Liu等^[11]使用ResNet进行DOA估计,在理想条件下可以有效估计信源角度。吴双等^[12]提出标签分解方法用于DOA网络训练,将one-hot标签分解为互质小标签,利用这些小标签对不同范围的空间谱进行独立训练,降低了大类别条件下分类器的训练难度。Ahmet^[13]通过提取信号协方差矩阵的实部、虚部和相位,组成一个三通道矩阵,并将其作为CNN的输入信号,利用MUSIC算法的估计结果作为神经网络的学习目标,达到了与MUSIC算法相近的估计效果。Julian等^[16]提出了一种增广MUSIC算法,其网络主要分为三个部分:第一部分为一个循环神经网络RNN,通过RNN网络估计信号的协方差矩阵;第二部分为特征分解和MUSIC谱峰搜索;第三部分为一个DNN,用于寻找谱峰,估计信源角度。这种方法等效于在MUSIC算法之前加一个降噪模块,使得网络可以在低信噪比情况下进行有效的DOA估计。

以上基于神经网络的估计方法克服了传统特征分解方法鲁棒性差的问题,在理想条件下,达到了和传统算法相近的精度。但是在实际应用中,阵列接收到的信号存在大量相干信号,并且阵列存在阵元失配和互耦等问题。针对这些问题,在考虑阵元失配、互耦和相干信源的前提下,本文提出了一个多通道CNN+DNN的DOA估计网络,并针对该网络提出了新的目标函数生成方法。使用阵列输出信号的协方差矩阵构建三通道输入信号,使用拟合公式生成目标函数。实验结果表明,该方法具备鲁棒性高,可以解相干和估计精度高的优点。

2 阵列信号模型

2.1 ULA 模型

对于一个M阵元的均匀线性阵列(Uniform Linear Array, ULA),为了满足空间采样定理和尽可能高的分辨率,通常设置其阵元间距为入射信号的半波长 $\lambda/2$ 。假设入射信号为远场窄带信号,那么可以认为阵列中每个阵元接收到的信号幅度一致,且只存在相位延迟。因此,在设定参考阵元后,可以将每个阵元与参考阵元之间的相位差组成

一个导向矢量 \mathbf{A}

$$\mathbf{A} = [1 \ e^{-j2\pi d \sin \theta} \cdots \ e^{-j2\pi(M-1)d \sin \theta}]^T \quad (1)$$

式中 θ 为信号入射角度, 当有多个信号同时入射时, \mathbf{A} 为一个导向矩阵, 式中 T 表示矩阵转置。设信号的幅度为 1, 此时, ULA 输出信号可以表示为:

$$\mathbf{X} = \mathbf{As} + \mathbf{n} \quad (2)$$

其中 \mathbf{n} 为加性高斯白噪声; s 为入射信号; X 为阵列的输出信号矩阵。 s 是一个 $K \times N$ 矩阵, K 与 N 分别对应信源数和快拍数。

2.2 误差模型

在实际应用中, 阵元之间存在互耦、幅度失配、相位失配等问题, 这些问题会严重地影响 DOA 估计结果。此外, 当入射信号中存在相干信号时, 由于阵列输出信号的协方差矩阵是欠秩矩阵, 直接对其进行特征分解将不能得到有效的结果, 因此传统的基于特征分解方法无法估计相干信号。

当阵列存在互耦时, 阵元间存在相互干扰, 这将导致不同阵元接收到的信号幅度不相等, 且相位和阵元位置不为线性关系。本文使用 B-band 互耦模型来合成阵列输出信号, 在 B-band 模型中, 互耦表现为其他阵元接收到的信号经过衰减和相位延迟后叠加到当前阵元^[20]。以一个耦合矩阵 \mathbf{C} 表示阵元间的互耦系数, 此时 ULA 输出信号 \mathbf{X} 可表示为

$$\mathbf{X} = \mathbf{Cas} + \mathbf{n} \quad (3)$$

其中 $\mathbf{C} \in \mathbb{C}^{M \times M}$, M 为阵元数。在 B-band 模型中, 互耦系数矩阵 \mathbf{C} 表示如下。

$$\langle \mathbf{C} \rangle_{d_1, d_2} = \begin{cases} c_{|d_1 - d_2|}, & |d_1 - d_2| \leq B \\ 0, & \text{others} \end{cases} \quad (4)$$

d_1, d_2 是 ULA 中任意两个阵元的位置; B 是一个常数, 当阵元间距大于 B 后, 互耦影响可以忽略不计, c_0, c_1, \dots, c_B 是互耦系数, 系数满足

$$c_0 = 1 > |c_1| > |c_2| > \dots > |c_B| \quad (5)$$

通常假设互耦系数的幅度和其分布间距呈反比关系, 即 $|c_k c_l| = l/k$, 在均匀线阵中, \mathbf{C} 为一个 topelize 矩阵。

$$\mathbf{C} = \begin{bmatrix} c_0 & c_1 & \cdots & c_{M-1} \\ c_1 & c_0 & \cdots & c_{M-2} \\ \vdots & \vdots & \ddots & \vdots \\ c_{M-1} & c_{M-2} & \cdots & c_0 \end{bmatrix} \quad (6)$$

对于 ULA 中的一个阵元来说, 幅度误差和相位误差体现在采样上, 每一次信号采样, 样本都会被施加固定的幅度增益和相位偏移。假设有 K 个

信号入射到阵列上, 其导向矩阵可以表示为

$$\mathbf{A}_p = \begin{bmatrix} p_0 a_{0,0} & \cdots & p_0 a_{0,K} \\ \vdots & \ddots & \vdots \\ p_{M-1} a_{M-1,0} & \cdots & p_{M-1} a_{M-1,K} \end{bmatrix} \quad (7)$$

其中 p_m 是一个复数, 表示第 m 个阵元的幅度增益和相位偏移, $m \in [0, M)$ 。将系数 p_m 写成一个对角矩阵 P :

$$P = \text{diag}([p_0 \cdots p_{M-1}]) \quad (8)$$

此时, ULA 输出信号表示为

$$\mathbf{X} = \mathbf{CPAs} + \mathbf{n} \quad (9)$$

位置偏差会影响阵元间的相位差, 从而影响实际的导向矢量, 若位置偏差为

$$\mathbf{d} = [0 \ \Delta d_1 \ \cdots \ \Delta d_{M-1}] \quad (10)$$

则导向矢量的相位偏移 \mathbf{A}'_p 为

$$\mathbf{A}'_p = [1 \ e^{-j2\pi\Delta d_1 \sin \theta} \ \cdots \ e^{-j2\pi\Delta d_{M-1} \sin \theta}]^T \quad (11)$$

此时, ULA 的导向矢量 \mathbf{A}' 表示为

$$\mathbf{A}' = \mathbf{A} \odot \mathbf{A}'_p \quad (12)$$

综合各种误差后, ULA 输出信号表示为

$$\mathbf{X} = \mathbf{CPA}'s + \mathbf{n} \quad (13)$$

使用式(13)即可以合成带互耦误差、幅度误差、相位误差和位置误差的 ULA 输出信号。

3 网络结构与数据构建

3.1 网络结构

本文使用图 1 所示多通道 CNN+DNN 网络, 多通道网络将空间谱划分成了多个范围更小的谱, 每个通道估计一个小范围的空间, 使得网络训练过程更加高效。为了控制网络整体大小, 需要控制卷积层的大小以及全连接层的大小。在卷积网络中, 对于一个输入维度为 $n_{in} \times w_{in} \times h_{in}$ 的信号, 当使用有效填充(valid padding)进行卷积时, CNN 输出的大小为

$$w_{out,v} = \frac{w_{in} - F}{st} + 1 \quad (14)$$

使用相同填充(same padding)进行卷积时,

$$w_{out,s} = \frac{w_{in} + 2 * pad - F}{st} + 1 \quad (15)$$

其中, n_{in} 表示 CNN 输入的维度; w_{in} 表示 CNN 输入的宽度; $w_{out,v}$ 与 $w_{out,s}$ 为 CNN 输出的宽度; F 表示卷积核的大小; st 表示卷积的步长, pad 表示特征图的填充圈数。当卷积层的输出与全连接层连接时, 如果卷积层输出数据量较大, 会导致网络参数量过大, 而增加网络参数对估计效果没有明显提

升,因此,本文尽可能使用有效填充,以减小卷积层的输出大小。同时,通过有效填充减少数据后,由于

最后一层卷积层输出的数据量已经很少,且矩阵维度较低,不需要再进行池化操作。

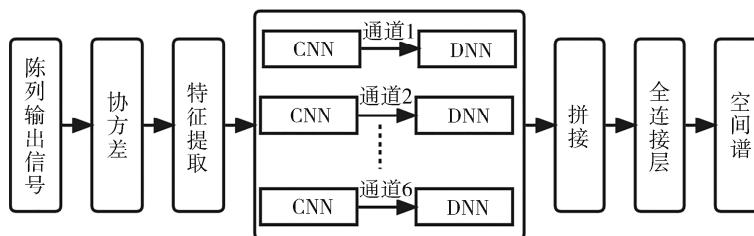


图 1 DOA 网络框架
Fig. 1 Overall DOA network framework

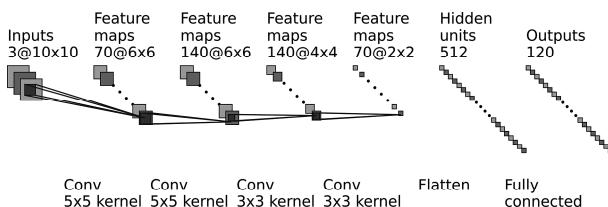


图 2 单通道的结构
Fig. 2 Deep network architecture of single channel

图 2 为 10 阵元时的单通道网络结构,表 1 为 10 阵元时的单通道完整网络参数,其输入维度为 $3 \times 10 \times 10$ 。第一个卷积层的卷积核大小为 5×5 ,卷积核数目为 70, 填充方式为‘valid’,步长为 1,根据式(14),其输出大小为 $70 \times 6 \times 6$;第二个卷积层的卷积核大小为 5×5 ,卷积核数目为 140, 填充方式为‘same’,步长为 1,根据式(15),其输出大小为 $140 \times 6 \times 6$;第三个卷积层的卷积核大小为 3×3 ,卷积核数目为 140, 填充方式为‘valid’,步长为 1,输出大小为 $140 \times 4 \times 4$;第四个卷积层的卷积核大小为 3×3 ,卷积核数目为 70, 填充方式为‘valid’,步长为 1,输出大小为 $70 \times 2 \times 2$ 。将最后一层卷积层的输出向量化后输出到 512 个单元的全连接层,进行特征识别,最后接一个 120 大小的全连接层作为本通道的输出。对六个通道的输出进行拼接,合成一个含 720 个点,角度范围从 -90° 到 90° 的空间谱。

当取不同阵元数时,应适当改变卷积核的大小和数目。表 1 的网络参数中,参数顺序与 keras 相关网络层的参数顺序一一对应。

3.2 构建输入信号

本文中网络输入为阵列输出信号的协方差矩阵。其构建方式如下。

使用频率为 1 GHz 的正弦信号作为入射信号。当信源数目为 K 时,将 $[-\pi/3, \pi/3]$ 角度区间划分为 K 个子区间,子区间的分割点为 $-\pi/3 +$

$2k\pi/3k, k$ 是 $[0, K]$ 区间内的整数。若信号编号从 0 开始,则第 k 个信号的入射角度 θ_k 为 $[-\pi/3 + 2k\pi/3k, -\pi/3 + 2(k+1)\pi/3k]$ 区间内均匀分布的随机值。

表 1 一个通道的网络信息

Tab. 1 Parameters of one channel

网络层类型	输出大小	网络参数
卷积层	$70 \times 6 \times 6$	$70, 5 \times 5, 1 \times 1, \text{valid}$
批标准化	$70 \times 6 \times 6$	
激活层	$70 \times 6 \times 6$	relu
卷积层	$140 \times 6 \times 6$	$140, 5 \times 5, 1 \times 1, \text{same}$
批标准化	$140 \times 6 \times 6$	
激活层	$140 \times 6 \times 6$	relu
卷积层	$140 \times 4 \times 4$	$140, 3 \times 3, 1 \times 1, \text{valid}$
批标准化	$70 \times 4 \times 4$	
激活层	$70 \times 4 \times 4$	relu
卷积层	$70 \times 2 \times 2$	$70, 3 \times 3, 1 \times 1, \text{valid}$
批标准化	$70 \times 2 \times 2$	
激活层	$70 \times 2 \times 2$	relu
Flatten	280	
Dropout	280	0.3
全连接层	512	512, relu
Dropout	512	0.3
全连接层	120	

样本的位置误差设置为信源半波长的 5%,即式(10)中 Δd_m 服从 $[-\lambda/40, \lambda/40]$ 的均匀分布, λ 为信号波长, $m \in [0, M]$, Δd_m 由随机函数生成,阵元位置 $\mathbf{D} = [d_0, d_1, \dots, d_{M-1}]$ 。

由于神经网络具备较高的鲁棒性且本文网络是针对带误差的信号,因此,本文按照均匀线阵的模型对信号添加互耦。根据 B-band 模型,互耦系数定义如下^[20]。

$$\begin{aligned} c_l &= c_1 e^{-j(l-1)\pi/8} / l \\ l &= |d_i - d_j|, i, j \in [0, M] \end{aligned} \quad (16)$$

其中, d_i 和 d_j 分别表示第 i 和第 j 个阵元的位置, $c_1 = c e^{j\pi/3}$, 系数 c 服从 $[0, 0.4]$ 的均匀分布, 由随机函数生成。当 $c > 0.3$ 时, 阵列具有强耦合, 反之为弱耦合。即本文训练数据中既存在弱耦合数据, 也存在强耦合数据。

幅度误差设置为 5%, 相位误差设置为 $\pm 5^\circ$, 式(8)中 p_m 的实部服从在 $[0.95, 1.05]$ 区间内的均匀分布, p_m 的虚部服从在 $[e^{-j\pi/3b}, e^{j\pi/3b}]$ 区间内的均匀分布。

根据式(4)(8)(12)(13)可生成 ULA 输出信号 \mathbf{X}_n , n 为样本序号。

对 ULA 输出信号求协方差:

$$\mathbf{R}_n = E[\mathbf{X}_n \mathbf{X}_n^H], \mathbf{R}_n \in \mathbb{C}^{M \times M} \quad (17)$$

分别提取协方差矩阵 \mathbf{R}_n 的实部、虚部和相位构建一个 $3 \times M \times M$ 的三通道矩阵, 作为网络的输入。

3.3 构建目标函数

传统的 DOA 估计方法是利用的是阵列输出信号与 DOA 之间的线性关系, 神经网络的训练过程就是学习这种线性映射。在理想条件下, 使用传统方法可以得到非常尖锐且近乎理想的超分辨率空间谱。但是, 不论是误差或者是相干信源, 都可能导致传统方法估计出来的空间谱分辨率降低甚至无法分辨信号。为了让神经网络学习该线性映射并消除由误差和相干带来的估计误差, 本文通过拟合理想状态下的空间谱来生成目标信号, 因此, 无论是何种误差, 信源是否相干, 神经网络都有一个正确的学习目标。

令信源数目为 1, 入射角度为 0° , 使用 MUSIC 算法对 ULA 输出信号进行空间谱估计, 此时的空间谱有一个尖锐的谱峰。以谱峰峰顶为起点, 截取空间谱的后半部分数据, 使用 MATLAB 拟合工具箱, 用指数函数对其进行拟合。拟合函数可由下式表示:

$$y = a x^b + c \quad (18)$$

根据拟合结果, 式(1)中 a, b, c 的值分别为 41.74, -0.7988 , -44.3 , 通过修改 b 的值, 可以改变谱峰衰减速度, b 越小, 谱峰衰减越快。本文中 $a = 44$, $b = -2$, $c = 44$, x 为当前格点距离信源格点的网格数目。

利用式(18), 可以得到半个空间谱, 将其进行对称处理, 即可得到一个完整的空间谱。假设空间谱由 n 个点构成, 同时 n 为一个偶数。取 x 为

$[1, n/2+2]$ 区间内的整数, 使用式(18)生成空间谱 y_{h0} 。取 y_{h0} 的第 2 至 $n/2+1$ 个元素, 将其翻转后拼接在 y_{h0} 前面, 即可以得到一个入射角度为 0° , 信源数为 1 的空间谱 y_0 。

$$y_0 = \begin{cases} 44(x-1)^{-2} - 44, & -n/2+1 \leq x \leq 0 \\ 44(x+1)^{-2} - 44, & 0 < x \leq n/2 \end{cases} \quad (19)$$

式中 $x \in [0, n/2-1] \cup [n/2+2, n+2]$ 。

当信号入射角度为 θ 时, 只需要将 y_0 进行循环右移 $\lfloor \theta \times n / \pi \rfloor$ 个网格, 即可获得入射角为 θ 时的空间谱, $\lfloor \cdot \rfloor$ 表示向下取整。当有多个信号同时入射时, 将不同角度的空间谱进行叠加, 移除叠加后的偏置即可获得多个信号从不同角度同时入射时的空间谱。根据该方法, 可为输入样本生成对应的目标函数。

4 仿真实验与结果分析

4.1 训练集数据

阵元数目设置为 10, 信号为频率 1 GHz 的正弦相干信号, 信号数目为 $[1, 7]$ 内的整数, 入射角度为 $[-\pi/3, \pi/3]$, 不同信号数的样本数为 10 000 条, 共 70 000 条训练样本。使用 3.2 节与 3.3 节中所描述的方式生成网络的输入样本和目标函数。

4.2 训练网络设置

训练平台为 AMD R5 2600 + GTX960 2G, 训练环境为 Windows10 + tensorflow2.7 + python3.8。

构建如表 1 所示的六通道网络模型, 由于显存有限, batch-size 设置为 16, 避免显存溢出, 同时, 选择所需内存较少的 Adam 优化算法。损失函数选择 MSE, epoch 设置为 100, 学习速率设置为 0.001, 此时学习曲线收敛速度适中, 在大约 50 个 epoch 后学习曲线基本收敛完成。

4.3 测试集数据

测试集中, 测试信号为频率 1 GHz 的正弦相干信号。不同信源数目样本各 1000 条, 每个样本中的信号从不同方向入射。互耦系数按照式(16)添加, 式(16)中 c_1 的系数 $c = rho \times 0.4$, rho 为调节误差大小的误差因子, 幅度误差 p_r 取

$$\begin{aligned} p_r &= (0.05 \times rho \times \\ &[-1, -1, -1, 1, -1, 1, 1, 1, 1]) + e_M \\ e_M &= [1, 1, 1, 1, 1, 1, 1, 1, 1] \end{aligned} \quad (20)$$

相位误差 p_ϕ 取

$$\mathbf{p}_p = \pi \times rho \times [1, -1, 1, 1, -1, -1, -1, 1, 1, 1] / 36 \quad (21)$$

位置误差 d' 取

$$d' = 0.05 \times rho \times [1, -1, -1, -1, 1, -1, 1, 1, -1, 1] \quad (22)$$

通过改变误差因子 rho 可改变误差大小, 实验测试了 rho 从 0.1 至 1, SNR 为 0 dB 和 10 dB 时的估计效果, 通过准确率来比较 DOA 估计效果, 估计误差小于 1° 的结果定义为准确, 大于 1° 的定义为错误。

4.4 实验步骤

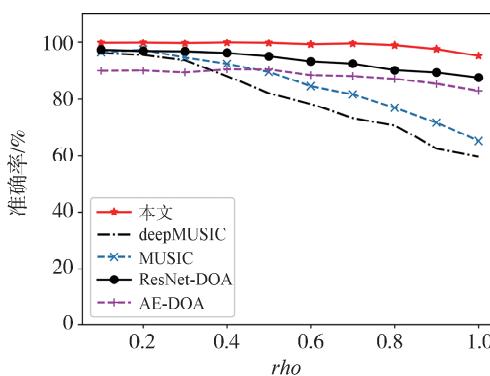
数据集生成主要描述网络训练前数据生成的步骤如算法 1; DOA 估计测试主要描述对网络性能进行测试的步骤如算法 2.

算法 1 数据生成

输入: M, K, N, N_s, f_c

输出: 训练数据集 x_train, y_train

- 1) 生成 K 个相同正弦入射信号 $s, s \in R^{K \times N}$
- 2) 根据式(19)构造 y_0
- 3) for $i=1 \rightarrow N_s$ do // i 表示样本编号
- 4) $C \Leftarrow toeplitz(c_0 \ c_1 \cdots c_{M-1})$
- 5) $P \Leftarrow diag([p_0 \cdots p_{M-1}])$
- 6) $d \Leftarrow [0 \ \Delta d_1 \cdots \Delta d_{M-1}]$
- 7) for $k=1, 2, \dots, K$ do
- 8) // k 表示第 k 个信号
- 9) 在 3.2 节中划定区间内随机生成 θ_k
- 10) $A_k \Leftarrow [1 \cdots e^{-j2\pi(M-1)d \sin \theta_k}]$
- 11) $A_{kp} \Leftarrow [1 \cdots e^{-j2\pi \Delta d_{M-1} \sin \theta_k}]$
- 12) end for



(a) 信源数为 2

- 13) $A' \Leftarrow A \odot A_p$
- 14) $X_i \Leftarrow CPA's + n$ // n 表示高斯白噪声
- 15) $R_i \Leftarrow E[X_i X_i^H], R_i \in C^{M \times M}$
- 16) 提取 R_i 的实部、虚部与相位至 x_train_i
- 17) 将 y_0 移位叠加, 存入 y_train_i
- 18) end for
- 19) return x_train, y_train // 返回数据集

算法 2 DOA 估计测试

输入: 网络参数

输出: DOA 估计结果

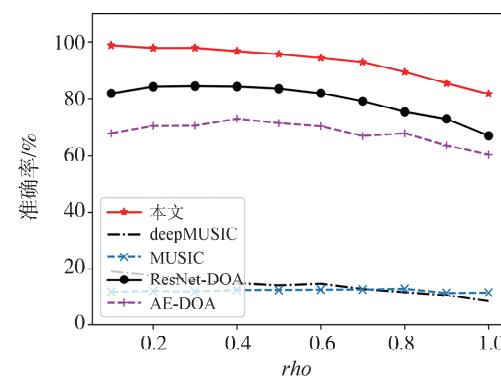
- 1) 调用数据生成算法生成 x_test, y_test
- 2) 构建网络
- 3) 加载网络参数
- 4) 向网络输入 x_test
- 5) 生成 DOA 估计空间谱
- 6) y : 寻找谱峰并得到对应的角度集合 y
- 7) 计算 y 与 y_test 之间的误差

参数量: 10 597 112

Flops: 48.8MFlops

4.5 实验结果

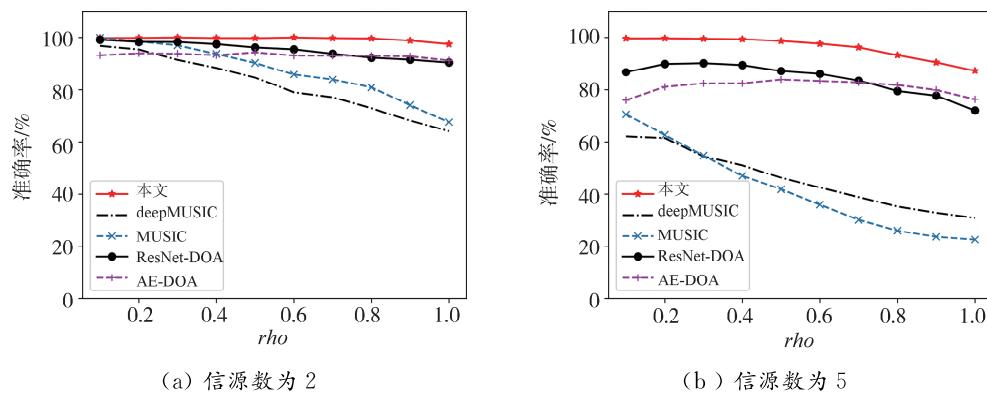
本文对比了传统空间平滑 MUSIC 算法^[4]、自编码多通道神经网络^[8]、基于 ResNet 的 DOA 估计方法^[10]以及 deep MUSIC 估计方法^[12]. 由于对文献[8]与文献[10]的网络仿真效果较差, 在未出现过拟合的前提下, 本文将文献[8]中每层网络的参数量扩大 10 倍, 文献[10]中每层网络的参数量扩大 2 倍, 同时将文献[10]的目标函数更改为本文中所提出的目标函数, 从而达到图 3~图 5 中所示效果.



(b) 信源数为 5

图 3 0 dB 下两个信源和五个信源时 1000 个样本的估计准确率

Fig. 3 Accuracy of 1000 samples with two sources and five sources at 0 dB



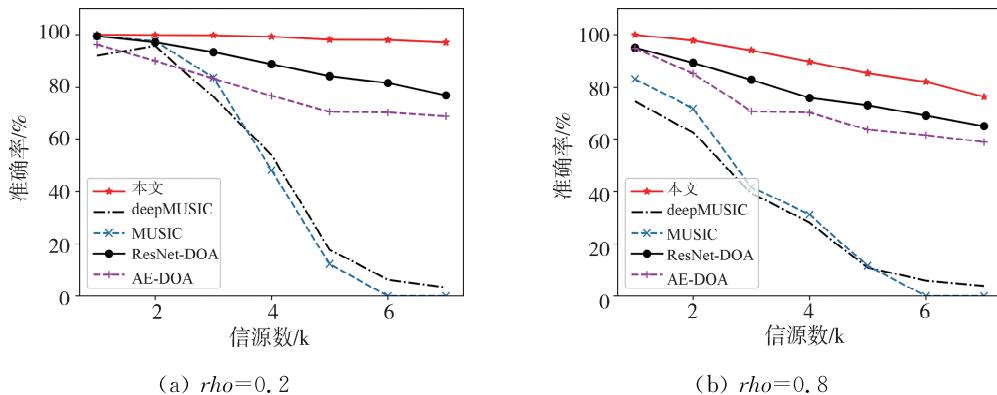
(a) 信源数为 2

(b) 信源数为 5

图 4 10 dB 下两个信源和五个信源时 1000 个样本的估计准确率
Fig. 4 Accuracy of 1000 samples with two sources and five sources at 10 dB

图 3 与图 4 中 MUSIC 曲线为使用空间平滑后的 MUSIC 算法估计的结果, AE-DOA 曲线为对文献[8]的自编码器+多通道网络的仿真结果, ResNet-DOA 曲线为对文献[10]的仿真结果, deepMUSIC 曲线为对文献[12]的仿真结果。图 3 与图 4 的结果显示, 信源数目较少时, 本文的方法和文献[8,10]中的方法在不同误差因子下都可以达到

90%以上的准确率,且本文的准确率明显高于文献[8,10]的准确率。当误差因子过大时,空间平滑后的 MUSIC 算法和文献[8]的估计效果都出现了较大的下降,准确率由误差因子较小时的 97%降到了 60%。当信源数目较多时,本文方法在 0 dB 与 10 dB 下都可以保持在 80%以上的准确率,超出其他方法至少 5%。

(a) $\rho = 0.2$ (b) $\rho = 0.8$ 图 5 0 dB 下不同误差因子时 1000 个样本的估计准确率
Fig. 5 Accuracy of 1000 samples with variant error factor at 0 dB

根据图 5 结果显示, 当误差较小时, 随着信源数的增加, 本文方法的准确率一直在 95%以上, 而其他方法的准确率有明显的下降, 下降最少的也降到了 80%。当误差较大时, 随着信源数增加, 本文方法准确率也出现了明显的下降, 由 1 个信源时的 99%降到 7 个信源时的 80%, 但最差时结果仍高于其他方法。

5 结 论

以往基于神经网络的 DOA 估计算法没有考虑阵列存在误差和信源相干的情况。本文在引入多种阵列误差和相干信号后, 针对该信号模型设计了一个多通道的 CNN+DNN 网络。同时, 为了解决

生成训练样本时, 由于误差大小改变, 相干信源数目变化所引起的目标信号变化, 本文通过拟合理想条件下 MUSIC 算法估计的空间谱, 根据拟合结果设计了网络的目标函数。拟合的目标函数更加接近理想条件下由线性变化得到的空间谱, 使得网络可以更有效地学习 ULA 输出信号与空间谱之间的线性规律, 在不同误差条件下都可以进行有效的 DOA 估计。仿真实验结果也验证了本文方法对 DOA 估计的有效性, 相对于传统方法和过去考虑简单误差条件或者理想条件下的 DOA 估计网络, 本文方法具有更好的估计效果和更高的鲁棒性。同时, 相比于空间平滑算法, 该方法具有更高的自由度。

参考文献:

- [1] Rao B D, Hari K V S. Performance analysis of Root-Music [J]. IEEE Trans Acoust, Speech, Signal Process, 1989, 12: 37.
- [2] Roy R, Kailath T. ESPRIT-estimation of signal parameters via rotational invariance techniques [J]. IEEE Trans Acoust, Speech, Signal Process, 1989, 7: 37.
- [3] Zheng Z, Wang W Q, Kong Y, et al. MISC array: a new sparse array design achieving increased degrees of freedom and reduced mutual coupling effect [J]. IEEE T Signal Processing, 2019, 67: 1728.
- [4] 石要武, 陈森, 单泽涛, 等. 基于特征空间 MUSIC 算法的相干信号波达方向空间平滑估计[J]. 吉林大学学报: 工学版, 2017, 47: 268.
- [5] Wu L, Huang Z. Coherent SVR learning for wideband direction-of-arrival estimation [J]. IEEE Signal Proc Let, 2019, 26: 642.
- [6] Barthelme A, Utschick W. DoA estimation using neural network-based covariance matrix reconstruction [J]. IEEE Signal Proc Let, 2021, 28: 783.
- [7] Hu D, Zhang Y, He L, et al. Low-complexity deep-learning-based DOA estimation for hybrid massive MIMO systems with uniform circular arrays [J]. IEEE Wireless Commun Lett, 2020, 9: 83.
- [8] Liu Z, Zhang C, Yu P S. Direction-of-arrival estimation based on deep neural networks with robustness to array imperfections [J]. IEEE Trans Antennas Propag, 2018, 66: 7315.
- [9] Huang H, Yang J, Huang H, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system [J]. IEEE Trans Veh Technol, 2018, 67: 8549.
- [10] Liu W. Super resolution DOA estimation based on deep neural network [J]. Sci Rep, 2020, 10: 19859.
- [11] 吴双, 袁野, 马育红, 等. 用于大规模深度卷积分类网络 DOA 估计的标签分解方法[J]. 信号处理, 2021, 37: 1.
- [12] Elbir A M. DeepMUSIC: multiple signal classification via deep learning [J]. IEEE Sens Lett, 2020, 4: 1.
- [13] Fan R, Si C K, Guo H S, et al. Direction finding for coherent sources with deep hybrid neural networks [J]. Int J Electron, 2021, 109: 1.
- [14] Cong J, Wang X, Huang M, et al. Robust DOA estimation method for MIMO radar via deep neural networks [J]. IEEE Sen J, 2021, 21: 7498.
- [15] Merkofer J P, Revach G, Shlezinger N, et al. Deep augmented music algorithm for data-Driven doa estimation [C]//Proceedings of the ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Singapore. Singapore: IEEE, 2022.
- [16] Habets A P. Broadband doa estimation using convolutional neural networks trained with noise signals [C]//Proceedings of the IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA). New Paltz, NY, USA: IEEE, 2017.
- [17] Li Q L, Zhang X L, Li H. Online direction of arrival estimation based on deep learning [C]//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Calgary, AB, Canada: IEEE, 2018.
- [18] Wu L, Liu Z, Huang Z. Deep convolution network for direction of arrival estimation with sparse prior [J]. IEEE Signal Process Lett, 2019, 26: 1688.
- [19] Rao B D, Hari K V S. Weighted subspace methods and spatial smoothing: analysis and comparison [J]. IEEE Trans Signal Process, 1993, 2: 41.
- [20] Liu C L, Vaidyanathan P P. Super nested arrays: linear sparse arrays with reduced mutual coupling—Part I: fundamentals [J]. IEEE T Signal Process, 2016, 64: 3997.

引用本文格式:

- 中 文: 钟东强, 何培宇, 喻伟闯. 基于神经网络的相干信源稳健 DOA 估计[J]. 四川大学学报: 自然科学版, 2023, 60: 023001.
- 英 文: Zhong D Q, He P Y, Yu W C. Robust DOA estimation of coherent sources based on neural network [J]. J Sichuan Univ; Nat Sci Ed, 2023, 60: 023001.