

基于深度卷积神经网络的 DOA 估计

郭书涵^{1,2}, 胡国平^{1,*}, 赵方正^{1,2}, 周豪¹, 张宇乐^{1,2}

(1. 空军工程大学防空反导学院, 西安, 710051; 2. 空军工程大学研究生院, 西安, 710051)

摘要 针对现有均匀线阵远场窄带非相干多目标估计算法对低信噪比、少快拍情况适应性差、运算复杂度高,以及现有深度学习方法难以有效提取数据复值特征的问题,提出基于深度卷积神经网络的波达方向估计方法。该方法将波达方向估计问题转换为阵列输出协方差矩阵到目标到达角度的逆映射问题,利用阵列输出协方差矩阵的 Hermitian 特性,提取其上三角阵的实部、虚部及相位特征,构造网络的输入数据,搭建包含三维卷积层的深度卷积神经网络用来提取数据特征,网络的标签对应目标的到达角度,从而实现多个信源的波达方向估计。试验仿真表明:该方法可以充分提取空间特征,提高波达方向估计精度并降低算法复杂度。所提方法在低信噪比、少快拍数的情况下,其估计精度明显优于 MUSIC、ESPRIT 以及 ML 算法。

关键词 波达方向估计;深度卷积神经网络;协方差矩阵;特征提取

DOI 10.3969/j.issn.2097-1915.2023.04.0010

中图分类号 TN953 **文献标志码** A **文章编号** 2097-1915(2023)04-0062-07

A DOA Estimation Based on Deep Convolutional Neural Network

GUO Shuhan^{1,2}, HU Guoping^{1,*}, ZHAO Fangzheng^{1,2}, ZHOU Hao¹, ZHANG Yule^{1,2}

(1. Air and Missile Defense School, Air Force Engineering University, Xi'an 710051, China;
2. Graduate School, Air Force Engineering University, Xi'an 710051, China)

Abstract Aimed at the problems that the existing Uniform Linear Array (ULA) far-field narrowband non-coherent multi-target estimation algorithms is poor in adaptability to low Signal-to-Noise Ratio (SNR), small snapshots in adaptability, high in computational complexity, and existing Deep Learning (DL) approaches are difficult to effectively extract the complex-valued features of data, a Direction of Arrival (DOA) estimation method based on Deep Convolution Neural Network (DCNN) is proposed. This method is to transform the DOA estimation problem into an inverse mapping problem from the array output covariance matrix to the target DOA, and to utilize the Hermitian characteristic of the array output covariance matrix for extracting the real part, imaginary part, and phase characteristics of an upper triangular array, building input data of a network, and building a deep convolutional neural network with a three-dimensional convolution layer to extract data features, and the labels of the network correspond to the DOAs, realizing the DOA estimation of multiple sources. The experimental simulations show that the method can fully extract spatial features, improve DOA estimation accuracy and reduce the complexity of the algorithm. Under condition of low SNR and small snapshots, the estimation accuracy of the proposed

收稿日期: 2023-02-22

基金项目: 国家自然科学基金(62071476)

作者简介: 郭书涵(1999-),女,河南安阳人,硕士生,研究方向为雷达信号与信息处理。E-mail: guoshuhan0304@163.com

通信作者: 胡国平(1964-),男,江西南昌人,教授,博士生导师,研究方向为雷达信号与信息处理。E-mail: hgp6068@163.com

引用格式: 郭书涵,胡国平,赵方正,等. 基于深度卷积神经网络的 DOA 估计[J]. 空军工程大学学报, 2023, 24(4): 62-68. GUO Shuhan, HU Guoping, ZHAO Fangzheng, et al. A DOA Estimation Based on Deep Convolutional Neural Network[J]. Journal of Air Force Engineering University, 2023, 24(4): 62-68.

method is significantly better than that of the MUSIC, the ESPRIT and the ML algorithms.

Key words direction of arrival estimation; deep convolutional neural network; covariance matrix; feature extraction

波达方向(direction of arrival, DOA)估计是雷达信号处理中的重要研究内容, DOA估计的基本问题是确定空间内各个信号到达阵列参考阵元的方向角^[1-2]。传统的DOA估计研究方法中的常规波束形成法^[3](conventional beam forming, CBF), 将传统的傅里叶变换方法应用于空间谱估计, 但其角度分辨力受到“瑞利限”影响, 由于天线阵列的孔径约束, 无法分辨处于同一波束宽度内的多个不同目标。Capon提出基于最小均方准则的最小方差法^[4](minimum variance method, MVM), 突破了常规波束形成方法中“瑞利限”的限制, 空间分辨力得到提高, 但估计精度有限, 需要在信噪比较高、快拍数较多的条件下才能达到高精度估计。Schmidt^[5]提出的多重信号分类方法(multiple signal classification, MUSIC)以及Roy和Kailath^[6]提出的旋转不变子空间参数估计法(estimation of signal parameters via rotational invariance techniques, ESPRIT)是子空间分类法的重要代表。MUSIC方法利用信号子空间和噪声子空间的正交性对接收信号的协方差矩阵进行分解, 划分空间进行估计, 显著增强了空间谱估计的超分辨能力, 大大提高了空间谱估计的精度。ESPRIT方法利用子空间的旋转不变特性得到子阵接收信号的相位差来估计信号角度, 其计算复杂度明显低于MUSIC算法, 但估计精度较低。上述2种子空间分类在信噪比低、快拍数少、信源相干、模型失配等非理想情况下, 协方差矩阵分解得到的信号子空间和噪声子空间都不够准确, 使得测向性能显著下降, 且矩阵分解计算量巨大。Ziskind和Wax^[7]提出的最大似然(maximum likelihood, ML)估计法是子空间拟合方法的代表算法之一。这类算法较子空间分类方法, 在信噪比低、快拍数少的条件下测向性能稳定, 且能够对相干信源进行估计。但此类方法属于多维非线性优化问题, 算法复杂度较高。

传统的DOA估计方法总体上是基于模型驱动的, 在理想条件下估计精度可以逼近克拉美罗界, 然而在存在阵元耦合、幅相误差、阵元位置误差等非理想模型失配的情况时, DOA估计性能显著下降。随着深度学习理论与方法的不断发展, 基于深度学习的DOA估计方法也随之发展, 并成为DOA估计新

的研究方向。深度学习类DOA估计方法基于数据驱动, 通过网络模型直接建立阵列接收数据与波达角度之间的映射关系, 能够有效解决上述问题, 同时其低信噪比、少快拍情况的适应能力、超分辨能力得到了增强, 计算复杂度也有所降低。

目前, 基于深度学习的DOA估计方法大致分为两类。一类是将DOA估计问题转化为神经网络分类问题, 将空间角度进行分类, 学习网络输入数据与DOA之间的映射关系。例如Liu等人^[8]提出一个两级框架, 分别采用多任务自编码器对参数空间进行粗划分以及并行多层分类器进一步划分子区域, 该框架以阵列接收数据协方差的实虚部作为输入, 然后提取特征, 实现阵列误差情况下的高精度测向。葛晓凯等人^[9]基于信号在空域内是稀疏的先验条件, 提出一种深度学习网络, 将卷积网络和全连接网络相结合, 输出为DOA的最大后验概率, 实现相干源DOA的近最大似然估计。吴双等人^[10]为解决大规模分类问题, 将原始标签分解为多个互质类别并分别建立分类器, 通过离线训练学习从阵列采样到参数空间的逆映射, 最后将小分类器的输出重构为原始one-hot标签。另一类是将DOA估计问题转化为神经网络回归问题。例如Wu等人^[11]将DOA估计作为压缩感知中稀疏线性逆问题, 提出了一种从大型训练数据集学习逆变换的深度卷积神经网络, 利用稀疏先验实时、有效地获得信号的DOA。针对现有研究中, 基于深度学习的DOA估计大多只考虑单个或2个目标, 基于此, Elbir^[12]提出DeepMUSIC深度学习框架, 设计了多个深度卷积神经网络, 划分子区域学习阵列接收数据的实虚部特征与其MUSIC空间谱特征的关系以实现多个目标的DOA估计。

本文针对均匀线阵远场窄带非相干多目标估计问题, 将DOA估计问题转化为神经网络分类问题, 将阵列接收协方差矩阵上三角阵的实部、虚部及相位作为网络输入, 有效降低了算法的时间复杂度及空间复杂度, 搭建了深度卷积神经网络, 提取数据特征, 并学习数据输入与标签之间的非线性映射关系, 从而实现在低信噪比、少快拍情况下的高精度DOA估计。

1 信号模型与数据集构建

1.1 均匀线阵模型

基于传统算法的 DOA 估计问题,大多通过建立模型给出阵列输出信号矢量及阵列导向矩阵从而得到信源的入射角度 θ_k [13]。假设 K 个远场窄带非相干目标信号源 $\mathbf{S}(t)=[s_1(t), s_2(t), \dots, s_K(t)]^T$ 以波方向 $\boldsymbol{\theta}=[\theta_1, \theta_2, \dots, \theta_K]^T$ 入射至阵元间距为 d 方向性任意的 M 阵元均匀线阵。阵列输出信号矢量 $\mathbf{X}(t)=[x_1(t), x_2(t), \dots, x_M(t)]^T$ 可表示为:

$$\mathbf{X}(t) = \sum_{k=1}^K \mathbf{a}(\theta_k) s_k(t) + \mathbf{N}(t) = \mathbf{A}(\boldsymbol{\theta}) \mathbf{S}(t) + \mathbf{N}(t) \quad (1)$$

式中: $\mathbf{N}(t)=[n_1(t), n_2(t), \dots, n_M(t)]^T$ 表示均值为 0, 方差为 σ^2 的高斯白噪声; $\mathbf{a}(\theta_k)$ 为阵列入射角为 θ_k 的入射信号的导向矢量; $\mathbf{A}(\boldsymbol{\theta})$ 为阵列的导向矩阵。

$$\mathbf{a}(\theta_k) = [1, e^{-j2\pi \frac{d}{\lambda} \sin \theta_k}, \dots, e^{-j2\pi(M-1) \frac{d}{\lambda} \sin \theta_k}]^T \quad (2)$$

$$\mathbf{A}(\boldsymbol{\theta}) = [\mathbf{a}(\theta_1), \mathbf{a}(\theta_2), \dots, \mathbf{a}(\theta_K)] \quad (3)$$

式中: λ 为信号波长; d 为阵元间距。

阵列输出 $\mathbf{X}(t)$ 的协方差矩阵为:

$$\mathbf{R}_{xx} = E[\mathbf{X}(t) \mathbf{X}^H(t)] = \mathbf{A}(\boldsymbol{\theta}) \mathbf{R}_s \mathbf{A}^H(\boldsymbol{\theta}) + \sigma^2 \mathbf{I} \quad (4)$$

式中: $E[\cdot]$ 表示数学期望; \mathbf{I} 为单位矩阵。

通常来说,空间信源个数要小于阵元数且空间谱具有空间稀疏性。将空域范围 $[-60^\circ, 60^\circ]$ 划分为 N 个间距为 $\Delta\varphi$ 的离散角度的集合 $\boldsymbol{\Phi}=[\varphi_1, \varphi_2, \dots, \varphi_N]^T$, 当空间中某个离散角度集合 $\boldsymbol{\Phi}$ 中有信号到达时, 其对应位置序号 $r_n=1$, 否则 $r_n=0$ 。则离散角度对应位置序号集合 $\mathbf{r}=[r_1, r_2, \dots, r_N]^T$ 。每个离散角度对应的导向矩阵、信号源、阵列输出可以重新表示为:

$$\tilde{\mathbf{A}}(\boldsymbol{\Phi}) = [\mathbf{a}(\varphi_1), \mathbf{a}(\varphi_2), \dots, \mathbf{a}(\varphi_N)] \quad (5)$$

$$\tilde{\mathbf{S}}(t) = [\tilde{s}_1(t), \tilde{s}_2(t), \dots, \tilde{s}_N(t)]^T \quad (6)$$

$$\tilde{\mathbf{X}}(t) = \tilde{\mathbf{A}} \mathbf{r}^T \tilde{\mathbf{S}}(t) + \mathbf{N}(t) \quad (7)$$

将 DOA 估计问题转化为阵列输出信号的协方差矩阵到离散集合中对应非零元素位置序号的映射问题。本文采用卷积网络解决 DOA 估计问题。将阵列输出 $\tilde{\mathbf{X}}(t)$ 协方差矩阵 $\tilde{\mathbf{R}}_{xx}$ 上三角阵的实部虚部及相位作为卷积神经网络的输入:

$$\tilde{\mathbf{R}}_{xx} = E[\tilde{\mathbf{X}}(t) \tilde{\mathbf{X}}^H(t)] \quad (8)$$

由于协方差矩阵是正定 Hermitian 方阵, 因此在训练阶段, 可将协方差矩阵 $\tilde{\mathbf{R}}_{xx}$ 的上三角阵代替

方阵进行特征提取, 可以有效降低输入数据规模及运算量 [14]。将离散角度序号集合 \mathbf{r} 作为网络的输出。测试阶段, 输出的离散角度序号集合 \mathbf{r} 的 K 个最大非零元素位置所对应的离散角度 φ , 即待估计信号到达方向的角度值。

1.2 数据集的构建

本文以信号协方差矩阵的实部、虚部及相位特征构建数据集作为深度学习网络的输入, 目标入射范围为 $[-60^\circ, 60^\circ]$, 变化间隔为 0.1° 遍历, 重复 100 次, 快拍数区间为 $[10, 500]$, 信噪比区间为 $[-10, 20]$, 最终产生样本数为 120 100, 即输入数据维度为 $K \times K \times 3$, 输出为 $1\ 201 \times 1$ 维向量。其中训练集与测试集按照 8:2 的比例随机选取。

2 网络模型及算法步骤

深度学习中的卷积神经网络是一种具有局部连接、权重共享等特性的深层前馈神经网络, 相较全连接前馈网络有更少的参数, 主要由卷积层、池化层和全连接层交叉堆叠而成。卷积层是卷积神经网络中最基础、最核心的组成单元, 通过卷积核提取输入数据的特征信息; 池化层的作用是进行特征选择, 降低特征维数, 避免过拟合; 全连接层在卷积神经网络中起到对样本分类或回归的作用。在卷积神经网络正向传播之后进行误差反向传播, 用来修正参数, 当训练误差小于设定阈值或者完成迭代后, 网络训练完成。本文的算法流程以及深度卷积网络模型如图 1 所示。

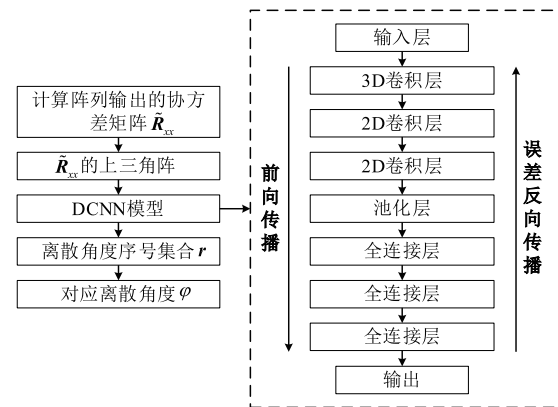


图 1 算法流程图

2.1 深度卷积神经网络模型

本文设计的卷积神经网络模型由 3 个卷积层, 连接一个池化层, 最后连接 3 层全连接层组成。模型的训练过程分为前向传播和反向误差传播。

2.1.1 卷积层

卷积层用于特征提取, 具有局部连接和权值共享的性质。每一个神经元通过卷积核与前一层的某

个局部窗口内的神经元相连,同一特征映射中的神经元所用卷积核相同,同一层中不同的特征映射的神经元所用卷积核不同,不同的卷积核从输入中提取不同特征,卷积后经过激活函数。

在卷积层中,第1层的输出特征映射 $\mathbf{Y}_p^{(l)}$ 是由所有输入特征映射 $\mathbf{x}_d^{(l)}$ 与卷积核 $\omega_{pd}^{(l)}$ 卷积之后,加上偏置 $b_p^{(l+1)}$ 所得的 $\mathbf{Z}_p^{(l)}$,再经过非线性激活函数后得到。卷积层的输出特征映射为:

$$\mathbf{Z}_p^{(l)} = \mathbf{W}_p^{(l)} * \mathbf{X}^{(l)} + b_p^{(l+1)} = \sum_{d=1}^D \omega_{pd}^{(l)} * \mathbf{x}_d^{(l)} + b_p^{(l+1)} \quad (9)$$

$$\mathbf{Y}_p^{(l)} = f(\mathbf{Z}_p^{(l)}) \quad (10)$$

本文使用的3个卷积层卷积核大小均为 3×3 ,卷积核较小无法扩大感受野,较大则参数较多、计算量较大,卷积核数量分别为 n_1 、 n_1 和 n_3 。输入数据为协方差矩阵的上三角阵,进行卷积操作前,首先对输入数据进行边界填充,以保留边界特征,根据卷积核的大小选择填充值为2,即在输入数据的上下左右各填充2行(列)数值0。卷积核每次滑动的步长为1,从左到右从上到下依次滑动完成卷积操作。以 5×5 的协方差矩阵为例,进行3次卷积示意图如图2所示。

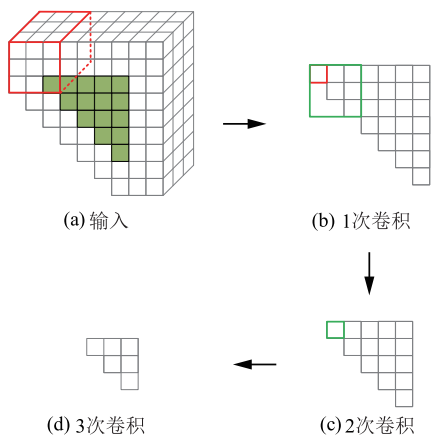


图2 卷积操作过程

图2(a)中绿色部分为输入的协方差矩阵上三角阵,深度维度分别为数据中的实部、虚部及相位,白色部分为边界填充,填充部分以及进行卷积时的数值缺失,均以数值0补全,仅对原始输入数据的长宽维度进行边界填充。第1次卷积为三维卷积,卷积核大小为 $3 \times 3 \times 3$,进行一次卷积之后变为二维卷积,再经2次卷积核大小为 3×3 ,步长为1的卷积操作后,得到图2(d)。

将卷积之后的结果加上偏置再经过激活函数来增强反向传播过程的非线性及收敛性。大多神经网络使用 ReLU^[15]、Sigmoid^[16]、Tanh^[17] 等函数作为激活函数,其中 ReLU 函数^[18]能够防止梯度饱和、

计算高效且具有很好的稀疏性,但是当输入数据存在负数时,随着训练的推进,部分输入落入硬饱和的区域,参数无法进行正常的更新,该神经元当前参数的梯度将恒为0,导致该神经元永久死亡。而 Leaky ReLU 函数在输入为负值时,也有一个很小的梯度 γ 以更新参数,避免 ReLU 函数而可能造成的永久神经死亡,本文选择 Leaky ReLU 函数作为卷积层的激活函数,其表达式如下:

$$\text{Leaky ReLU}(x) = \begin{cases} x, & x > 0 \\ \gamma x, & x \leq 0 \end{cases} = \max(x, \gamma x) \quad (11)$$

Leaky ReLU 函数图像如图3所示。




图3 Leaky ReLU 激活函数

2.1.2 池化层

卷积层之后连接池化层,池化层可以降低特征维度,减少数据冗余,避免过拟合,同时使得网络对小的局部形态改变保持特征不变性,以及拥有更大的感受野。池化层不包含需要学习的参数,池化类型一般分为最大池化和平均池化。最大池化是选择每个区域内所有神经元的最大值保留。池化层并不是卷积神经网络必备的操作,由于输入数据规模不会过大,本文仅在3层卷积层之后设计1层最大池化操作进行下采样,池化核的大小为 2×2 ,池化层的输入数据是经卷积层后输出的上三角阵,将上三角阵无重叠无遗漏地由左至右、由上至下依次划分为 2×2 的子区域,保留每个子区域的最大值,三角阵主对角线附近的池化子区域的缺失值做补0处理。以池化层输入为 5×5 的上三角阵为例,池化操作过程如图4所示。




图4 池化操作过程

2.1.3 全连接层

在池化层之后连接一层全连接层,全连接层的每个神经元都与上一层池化层的所有输出相连,将二维特征映射转化为一维向量。之前的卷积、池化

等操作将原始数据映射到隐藏层特征空间来提取特征,全连接层则将特征空间映射到样本标记空间来组合特征,实现分类或回归。全连接层可以看作特殊的卷积层,其输出为:

$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)} \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \quad (12)$$

$$\mathbf{a}^{(l)} = f(\mathbf{z}^{(l)}) \quad (13)$$

2.2 反向传播

在卷积神经网络中,需要学习的参数为卷积核中的权重及偏置,池化层中不包含需要更新的参数,可以通过误差反向传播算法^[19]更新卷积层的参数,使得网络输出与实际标签完全匹配。采用梯度下降法计算卷积层中参数的梯度,对每一层的误差进行反向传播,并再次更新梯度,直至网络目标函数收敛。卷积神经网络模型误差反向传播流程为:

1) 计算全连接层误差项并根据误差项计算权重梯度公式。根据一层的误差 $\delta^{(l)}$ 计算其前一层 $l-1$ 层误差 $\delta^{(l-1)}$,递推公式为:

$$\delta^{(l-1)} = (\mathbf{W}^{(l)})^T \delta^{(l)} \odot f'(\mathbf{z}^{(l-1)}) \quad (14)$$

式中: \mathbf{W} 为权重矩阵; f 为激活函数; \mathbf{z} 表示正向传播时激活函数的输入; \odot 运算表示 Hadamard 积。

2) 由误差项计算权重梯度和偏置梯度计算公式分别为:

$$\frac{\partial E}{\partial \mathbf{W}} = \delta^{(l)} (\mathbf{x}^{(l-1)})^T \quad (15)$$

$$\frac{\partial E}{\partial b} = \delta^{(l)} \quad (16)$$

式中: $\mathbf{x}^{(l-1)}$ 表示 $(l-1)$ 层的输入向量; E 表示损失函数。

3) 由于池化层未加激活函数,因此在该层仅需将误差项传播到前一层。首先将误差矩阵还原为池化前的大小,即恢复原来各子区域,其次对于最大池化,将误差值放在前向传播时记录的最大值位置处。

4) 计算卷积层反向传播误差,递推公式为:

$$\delta_{m,n}^{(l-1)} = \delta_{m,n}^{(l)} \frac{\partial x_{m,n}^{(l)}}{\partial x_{m,n}^{(l-1)}} = \delta^{(l)} * \text{rot180}(w_{m,n}^{(l)}) \odot \sigma'(x_{m,n}^{(l-1)}) \quad (17)$$

式中: $[*]$ 表示卷积运算; (m,n) 表示卷积运算时的起始坐标。

5) 计算卷积核权重梯度和偏置梯度,分别为:

$$\frac{\partial E}{\partial w_{m,n}^{(l)}} = \delta^{(l)} * \mathbf{r}(x_{m,n}^{(l-1)})^T \quad (18)$$

$$\frac{\partial E}{\partial b^l} = \sum_m \sum_n \delta^{(l)} \quad (19)$$

6) 计算一个批次内各权重梯度和偏置梯度之和,根据梯度下降法对权重和偏置进行更新:

$$\mathbf{W}^l = \mathbf{W}^l - \frac{\eta}{\text{batch}} \sum \frac{\partial E}{\partial \mathbf{w}^l} \quad (20)$$

$$b^l = b^l - \frac{\eta}{\text{batch}} \sum \frac{\partial E}{\partial b^l} \quad (21)$$

在前向传播后在进行反向传播,以修正卷积神经网络的卷积核和全连接层参数,直到到达指定的迭代次数。

2.3 本文算法及对比算法

本文采用 MUSIC 算法、ESPRIT 算法以及 ML 算法与所提基于深度卷积神经网络的 DOA 估计算法进行对比。MUSIC 算法是对阵列输出的协方差矩阵进行特征分解,利用信号子空间和噪声子空间的正交性进行划分空间,构造空间谱函数,搜索其谱峰实现 DOA 估计。ESPRIT 算法利用子空间的旋转不变性,不需要进行谱峰搜索,大幅降低了运算复杂度。ML 算法是通过选定未知参数以最大化似然函数,似然函数为观测所得信号的含有未知参数的条件概率密度函数,求得似然函数最大的解实现对未知参数的估计。以上方法在低信噪比、少快拍的情况下适应性差、运算复杂度高,本文设计的基于深度卷积的 DOA 估计方法在此类情况下能够有效提高 DOA 估计性能。具体步骤见表 1。

表 1 基于深度卷积神经网络的 DOA 估计算法步骤

输入: 均匀线阵阵列协方差矩阵上三角阵的实部、虚部及相位;
输出: 多个目标的 DOA。
1. 计算阵列输出协方差矩阵 \mathbf{R}_{xx} 的上三角阵;
2. 提取上三角阵的实部、虚部及相位特征构成 $K \times K \times 3$ 维矩阵 \mathbf{X} ;
3. 将矩阵 \mathbf{X} 输入训练好的深度卷积神经网络,得到网络的输出向量 \mathbf{Y} ;
4. 取输出向量 \mathbf{Y} 中 K 个最大非零元素位置所对应的离散角度 φ ,即待估计信号到达方向的角度值。

3 仿真实验及结果分析

本文实验环境为 Matlab2020b,实现 MUSIC 算法、ESPRIT 算法、ML 算法以及本文所提基于深度卷积神经网络的 DOA 估计方法,对比分析不同方法不同条件下的估计性能。仿真条件为理想条件下 8 阵元的均匀线阵,阵元间距为 $\lambda/2$, λ 为信号波长,目标信源为 3 个独立的远场窄带信号,目标入射范围为 $[-60^\circ, 60^\circ]$ 。其中 MUSIC 算法和 ML 算法谱峰搜索步进为 0.1° ,深度卷积网络离散角度间隔 $\Delta\tilde{\theta} = 0.1^\circ$,激活函数 Leaky ReLU 中参数 $\gamma = 0.1$ 。本文采用蒙特卡洛法统计模拟对比不同算法不同条件下的 DOA 估计精度,估计精度性能使用均方误差来评估,均方根误差公式为:

$$\text{RMSE} = \sqrt{\frac{1}{NK} \sum_{i=1}^N \sum_{j=1}^K (\hat{\theta}_{ij} - \theta_{ij})^2} \quad (23)$$

式中: N 为蒙特卡洛试验次数; K 为目标信源个数, $\hat{\theta}_{ij}$ 和 θ_{ij} 分别为第*i*次测得的第*j*个目标的DOA估计值和真实值。

3.1 信噪比对DOA估计精度的影响

该对比试验条件为3个目标入射角为 -20° 、 10° 和 40° ,快拍数为256,信噪比区间为 $[-10, 20]$,变化间隔取1 dB。对比MUSIC算法、ESPRIT算法、ML算法以及本文方法,在其他参数相同,仅信噪比不同情况下的DOA估计精度,仿真并计算4种方法1000次蒙特卡洛重复实验的均方误差, RMSE随信噪比变化关系如图5所示。

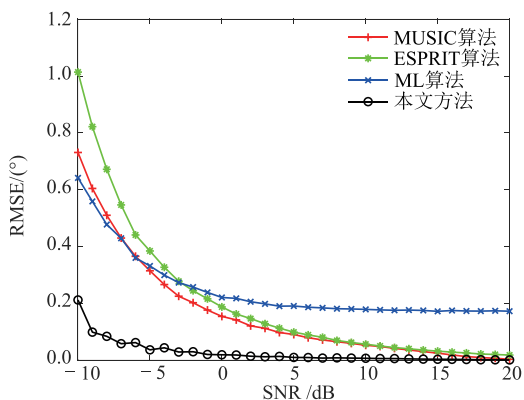


图5 信噪比对DOA估计精度的影响

由仿真结果可以看出:①随着信噪比的增大,各算法的RMSE均减小,当信噪比增大到5 dB后,各算法RMSE减小的趋势均趋于平缓;②4种算法中,ESPRIT算法的DOA估计精度受信噪比影响较大,在信噪比较小的情况下,ML算法的估计精度较高,但随着信噪比增大,在信噪比达到5 dB后,其估计精度提升趋于平缓,估计精度较差;③本文所提基于深度卷积神经网络的DOA估计方法,在信噪比在 $-10 \sim 5$ dB区间内的RMSE远小于其他3种算法,且在信噪比超过 -5 dB后, RMSE随信噪比变化不敏感。因此,在相同信噪比,尤其是信噪比较低的情况下,本文所提方法的性能较其他算法更加优良。

3.2 快拍数对DOA估计精度的影响

该对比试验条件为3个目标入射角为 -20° 、 10° 和 40° ,信噪比为10 dB,快拍数区间为 $[10, 500]$,变化间隔取10。对比MUSIC算法、ESPRIT算法、ML算法以及本文方法,在其他参数相同,仅快拍数不同情况下的DOA估计精度,仿真并计算4种方法1000次蒙特卡洛重复实验的均方误差, RMSE随快拍数变化关系如图6所示。




图6 快拍数对DOA估计精度的影响

由仿真结果可以看出:①随着快拍数的增大,各算法的RMSE均减小,且在快拍数 $10 \sim 20$ 变化时,各算法的RMSE显著减小,在快拍数大于50后,各算法的RMSE减小的趋势均趋于平缓;②ESPRIT算法的DOA估计精度受快拍数影响较大,在快拍数大于50后, MUSIC算法与ESPRIT算法DOA估计精度相当;③本文方法在仿真实验设置的快拍数区间 $[10, 500]$ 内,其RMSE均小于其他3种算法,且在快拍数超过150后, RMSE随快拍数变化不敏感,性能较其他算法更加优良。

3.3 不同算法运行时间的比较

表2为快拍数为256的条件下,各算法的运行时间。运行时间取1000次蒙特卡洛实验的平均值。由表2可知,本文所提的基于深度卷积神经网络的DOA估计方法运行时间虽不及ESPRIT算法,但优于其他2种算法,ESPRIT算法运行时间最短,但其DOA估计精度较低,而本文方法在估计精度上有明显的优势且算法复杂度较低。

表2 不同算法运行时间的比较

方法	运行时间/s
MUSIC算法	0.171 6
ESPRIT算法	0.007 9
ML算法	0.286 9
本文方法	0.068 7

4 结语

针对传统算法对低信噪比、少快拍情况的适应性差的情况,本文提出了基于深度卷积神经网络的DOA估计方法,该方法将阵列输出协方差矩阵上三角阵的实部、虚部及相位特征作为网络输入,搭建深度卷积神经网络,提取数据特征,学习输入到目标的到达角度的映射,从而实现多目标DOA估计。通过实验仿真表明,该算法的估计性能在相同条件下优于MUSIC算法、ESPRIT算法以及ML算法,在低信噪比、少快拍的情况下,估计性能较其它算法优

势更加明显,同时算法复杂度低于 MUSIC 算法及 ML 算法。该方法提取上三角阵的实部、虚部及相位特征,降低了算法复杂度,充分利用输入数据信息。本文构建数据集信噪比与快拍数条件均为范围,若分别构造等信噪比不同快拍或是等快拍不同信噪比情况的数据集,估计精度会有效提高。

参考文献

- [1] ZHANG Y L, HU G P, ZHOU H, et al. Direction of Arrival Estimation of Generalized Nested Array via Difference-Sum Co-Array[J]. *Sensors*, 2023, 23(2): 906-926.
- [2] ZHANG Y L, HU G P, ZHOU H, et al. Hole-Free Nested Array with Three Sub-ULAs for Direction of Arrival Estimation [J]. *Sensors*, 2023, 23 (11): 5214-5227.
- [3] BARTLETT M. Properties of Sufficiency and Statistical Tests[J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1937, 160(901): 268-282.
- [4] CAPON J. High-Resolution Frequency-Wavenumber Spectrum Analysis[J]. *Proceedings of the IEEE*, 1969, 57(8):1408-1418.
- [5] SCHMIDT R. Multiple Emitter Location and Signal Parameter Estimation[J]. *IEEE Transactions on Antennas and Propagation*, 1986, 34(3): 276-280.
- [6] ROY R, KAILATH T. ESPRIT-Estimation of Signal Parameters via Rotational Invariance Techniques [J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1988, 37(7): 984-995.
- [7] ZISKIND I, WAX M. Maximum Likelihood Localization of Multiple Sources by Alternating Projection[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1988, 37(10): 1553-1560.
- [8] LIU Z M, ZHANG C W, YU P S. Direction-of-Arrival Estimation Based on Deep Neural Networks with Robustness to Array Imperfections[J]. *IEEE Transactions on Antennas and Propagation*, 2018, 66(12): 7315-7327.
- [9] 葛晓凯, 胡显智, 戴旭初. 利用深度学习方法的相干源 DOA 估计 [J]. *信号处理*, 2019, 35 (8): 1376-1384.
- [10] 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): 1-10.
- [11] WU L L, LIU Z M, Huang Z T. Deep Convolution Network for Direction of Arrival Estimation with Sparse Prior [J]. *IEEE Signal Processing Letters*, 2019, 26 (11) : 1688-1692.
- [12] ELBIR A M. DeepMUSIC: Multiple Signal Classification via Deep Learning[J]. *IEEE Sensors Letters*, 2020, 4(4): 1-4.
- [13] 张宇乐, 胡国平, 周豪, 等. 自由度和互耦联合优化的三阶嵌套阵 [J]. *信号处理*, 2021, 37 (2): 234-241.
- [14] ZHAO F Z, HU G P, ZHAN C H, et al. DOA Estimation Method Based on Improved Deep Convolutional Neural Network[J]. *Sensors*, 2022, 22(4): 1305.
- [15] NAIR V, HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines[C]//*Proceedings of the 27th International Conference on Machine Learning*. Haifa: Omnipress, 2010: 807-814.
- [16] HAN J, MORAGA C. The Influence of The Sigmoid Function Parameters on the Speed of Backpropagation Learning [C]// *From Natural to Artificial Neural Computation/International Workshop on Artificial Neural Networks*. Torremolinos: Springer, 1995: 195-201.
- [17] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-Based Learning Applied to Document Recognition [J]. *Proceedings of the IEEE*, 1998, 86 (11): 2278-2324.
- [18] MAAS A L, HANNUN A Y, NG A Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models[C]//*30th ICML Workshop on Deep Learning for Audio, Speech and Language Processing*. Atlanta:[s. n.], 2013.
- [19] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning Representations by Back-Propagating Errors[J]. *Nature*, 1986, 323(6088): 533-536.

(编辑:徐楠楠)