

# 基于深度学习的智能化高精度测向方法

赵伟豪<sup>1</sup>, 张君毅<sup>1,2</sup>, 李淳<sup>1</sup>

(1. 中国电子科技集团公司 第五十四研究所, 石家庄 050081;

2. 河北省电磁频谱认知与管控重点实验室, 石家庄 050081)

**摘要:** 提出了一种基于深度学习的智能化高精度快速波达方向 (DOA) 估计算法, 根据神经网络通过数据驱动而不依赖阵列流型的特点, 设计了基于卷积神经网络的 PhaseDOA-Net 回归网络模型实现估计算法, 引入特定模块对输入信号进行特征提取和处理, 提高网络模型的拟合效果, 用所提网络模型自主学习相位差矩阵与 DOA 之间的映射关系; 引入残差网络结构, 解决了卷积神经网络层数加深导致网络退化的问题; 仿真生成了具有噪声与幅相误差的信号数据集, 并构建信号相位差矩阵作为输入; 仿真结果表明, 本算法可以提供更高精度的估计性能, 大幅减小了估计时间, 解决了现有方法在阵列模型误差条件下无法准确得到 DOA 结果的问题; 通过基于实际信号环境中采集数据的训练与测试, 验证了系统对不同噪声、幅相误差的鲁棒性以及在不同信号频率更好的适应能力。

**关键词:** DOA 估计; 深度学习; 神经网络; 信号处理; 人工智能技术

## Intelligent High Accuracy Side Direction Method Based on Deep Learning

ZHAO Weihao<sup>1</sup>, ZHANG Junyi<sup>1,2</sup>, LI Chun<sup>1</sup>

(1. China Electronics Technology Group Corporation No. 54 Research Institute, Shijiazhuang 050081, China;

2. Hebei Province Key Laboratory of Electromagnetic Spectrum Cognition and Control, Shijiazhuang 050081, China)

**Abstract:** On the basis of deep learning, an intelligent estimation algorithm of high accuracy fast direction of arrival (DOA) is proposed. According to the characteristics of neural network driven by data and independent of array flow pattern, a PhaseDOA-Net regression network model based on convolutional neural network (CNN) is designed. Specific modules are designed to extract and process the features of input signals, which improves the fitting effect of the network model, the proposed network model is used to autonomously learn the mapping relationship between the phase difference matrix and DOA. The residual network structure is introduced to solve the problem of network degradation caused by the layer deepening of CNN. The data set with noise and amplitude phase error is generated by simulation, and a signal phase difference matrix is constructed as the network input. The simulation results show that the algorithm can provide higher estimation accuracy, greatly reduce estimation time, and solve the problem that the existing methods cannot accurately obtain DOA results under the condition of array model error. Through the training and testing based on the collected data in actual environment, it verifies the robustness of the system to different noises, amplitude phase errors and the great adaptability to different signal frequencies.

**Keywords:** DOA estimation; deep learning; neural network; signal processing; artificial intelligence technology

## 0 引言

波达方向 (direction of arrival, DOA) 定位技术是天线阵列信号处理领域内的重要分支, 利用天线阵列接收到的来波信号就能够有效实现准确的定位。在现有的测向方法中, 以多重信号分类 (multiple signal classification, MUSIC) 为代表的算法具有较高的分辨力、估计精度、稳定性等优点<sup>[1]</sup>。但需要对阵列矩阵进行数学分解, 如特征值分解或奇异值分解。但矩阵分解计算复杂, 且运算量大, 不适合实时处理, 在不同阵列误差环境下或缺少阵列流型误差的先验信息时进行 DOA 估计鲁棒性较差。而相关干涉仪

等算法抗干扰能力一般, 在低信噪比与高幅相误差条件下的 DOA 估计精度较差<sup>[2]</sup>。

基于模型的 DOA 估计算法性能依赖于输入数据的响应准确程度, 而基于深度学习的数据驱动架构已显示出具有更高的估计精度, 并且显示出更低计算复杂性, 增强在不同信噪比 (SNR)、幅相误差的环境下适应性。Wen lizhu 等人提出了基于卷积神经网络 (convolutional neural network, CNN) 宽带信号 DOA 估计模型, 比 DNN 结构的估计时间更少, 但对低信噪比信号的估计效果有待提高<sup>[3]</sup>。Ahmet M. Elbir 提出了一种用于多重信号分类的深度学习

收稿日期: 2022-10-13; 修回日期: 2022-10-31。

基金项目: 国家自然科学基金(U19B2028)。

作者简介: 赵伟豪(1998-), 男, 河北石家庄, 硕士, 主要从事通信与信息系统方向的研究。

引用格式: 赵伟豪, 张君毅, 李淳. 基于深度学习的智能化高精度测向方法[J]. 计算机测量与控制, 2023, 31(1): 15-21, 29.

框架 (DeepMUSIC), 设计了多个 CNN, 具有更高的估计精度, 并且显示出更低计算复杂性<sup>[4]</sup>, 但对于幅相误差较高条件下的 DOA 估计的性能较差。B. Shi 等人提出了一种复值卷积神经网络 (CCNN) 来更好地拟合具有复杂包络的电磁无人机信号。利用量子概率构造了一些映射函数, 并进一步分析了一些可能影响复值神经网络收敛性的因素。数值仿真表明, 所提出的 CCNN 比卷积神经网络收敛更快, DOA 估计结果更准确、更稳健<sup>[5]</sup>。H. Huang 等人通过离线学习和在线学习, 提出了一种新的超分辨率 DOA 估计和信道估计的 DNN 框架。其中离线学习是利用不同信道条件下的模拟数据进行训练, 在线学习是基于当前输入数据得到相应的输出数据。实验证实, 基于深度学习的方法可以获得比传统方法更好的 DOA 估计。肖等人提出了一种类似于深度残差网络的 DeepFPC 网络结构。DeepFPC 在低信噪比下具有较高的稀疏信号恢复性能和良好的 DOA 估计性能<sup>[6]</sup>。

对于非理想的传感器设计和制造工艺、阵列安装误差和传感器间相互干扰、背景辐射等原因, 以及信号接收环境和宽带信号等苛刻条件的时候, 阵列系统中存在各种缺陷, 建立分析信号传播的模型复杂困难, 对 DOA 估计的性能产生显著的负面影响。基于数据驱动、不需要对复杂场景和各种缺陷进行人为假设和简化。为解决现有阵列测向方法计算复杂度、存在阵列误差条件下测向性能恶化严重等问题, 提出一种基于深度学习高精度快速的 DOA 估计算法。设计了基于卷积神经网络的 PhaseDOA-Net 网络模型, 基于深度学习的数据驱动架构通过神经网络学习输入和输出数据之间的非线性关系, 学习不同环境条件下信号数据与 DOA 之间的映射关系, 将 DOA 预测问题转化为回归拟合问题, 通过回归算法找到最优拟合, 提高低信噪比与存在阵列误差时测向模型的泛化能力和容错能力, 达到更高的测向精度和更快的处理速度<sup>[5-6]</sup>。

### 1 阵列信号接收模型

设空间远场有一个窄带信号  $s(t)$  入射到天线阵列上, 由  $M$  个单元组成, 窄带信号的入射角度为  $\theta$ 。信号接收阵列模型如图 1 所示, 假设参考点收到的入射波信号为:

$$x_0(t) = s(t)e^{j\omega t} \quad (1)$$

式中,  $\omega$  是信号的角频率,  $s(t)$  为信号的复振幅。设  $\tau_m$  是阵元  $m$  收到的入射波相对于参考信号点收到的延时, 有:

$$x_m(t) = s(t - \tau_m)e^{j\omega(t - \tau_m)} \quad (2)$$




图 1 信号接收阵列模型

对于窄带信号, 时间上慢变化, 所以有:

$$s(t - \tau_m) \approx s(t) \quad (3)$$

同时考虑复基带信号, 可表示为:

$$x_m(t) = s(t)e^{-j\omega\tau_m} \quad (4)$$

将  $M$  个全向阵元收到的信号数字化表示, 可得到向量表示为:

$$\mathbf{X}(t) = \begin{bmatrix} x_0(t) \\ \vdots \\ x_{M-1}(t) \end{bmatrix} = s(t) \begin{bmatrix} e^{-j\omega\tau_0} \\ \vdots \\ e^{-j\omega\tau_{M-1}} \end{bmatrix} = s(t)\mathbf{a} \quad (5)$$

式中,

$$\mathbf{a} = [e^{-j\omega\tau_0}, \dots, e^{-j\omega\tau_{M-1}}]^T \quad (6)$$

它被称为阵列对信号源的方向矢量或导向矢量, 与入射波到达方向和阵列单元的几何位置有关<sup>[7]</sup>。

信号到达方向为  $\theta_l, l = 1, 2, \dots, L, L$  为信号源数目。阵列接收数据模型为:

$$\mathbf{X}(t) = \mathbf{A}(\theta)\mathbf{S}(t) + \mathbf{n}(t) \quad (7)$$

式中, 阵列的接收数据  $\mathbf{X}(t) = [x_0(t), x_1(t), \dots, x_{M-1}(t)]^T$ , 信号数据矩阵  $\mathbf{S}(t) = [s_1(t), s_2(t), \dots, s_L(t)]^T$ , 导向矢量矩阵  $\mathbf{A}(\theta) = [\mathbf{a}(\theta_1), \mathbf{a}(\theta_2), \dots, \mathbf{a}(\theta_L)]$ , 以均匀线阵为例, 式中  $\mathbf{a}(\theta_l) = [1, e^{(-j2\pi d \sin(\theta_l)/\lambda)}, \dots, e^{(-j2\pi d(M-1) \sin(\theta_l)/\lambda)}]^T, \lambda$  为信号波长,  $d$  为阵元间距, 噪声数据矩阵为  $\mathbf{n}(t) = [n_0(t), n_2(t), \dots, n_{M-1}(t)]^T$ <sup>[8]</sup>。

为模拟真实的信号接收环境, 在接收模型中引入阵列误差。存阵列误差在于不同的接收通道, 可引用一个通道误差矢量  $\mathbf{r}$ ,

$$\mathbf{r} = [(1 + \epsilon_0)e^{j\vartheta_0}, (1 + \epsilon_1)e^{j\vartheta_1}, \dots, (1 + \epsilon_{M-1})e^{j\vartheta_{M-1}}]^T \quad (8)$$

$\epsilon_0, \epsilon_1, \dots, \epsilon_{M-1}$  表示通道幅度误差,  $\vartheta_0, \vartheta_1, \dots, \vartheta_{M-1}$  表示通道相位误差。

引入幅相误差后的阵列接收数据改写为:

$$\mathbf{X}'(t) = \mathbf{X}(t)\mathbf{r} \quad (9)$$

针对复杂环境下对高精度快速测向的需求, 提出使用卷积神经网络方法提取信号数据的内在特征, 以智能化的方法来学习不同环境条件下信号数据与 DOA 之间的映射关系。

## 2 基于 PhaseDOA-Net 模型的 DOA 估计

### 2.1 PhaseDOA-Net 神经网络模型

分类网络模型通常将连续值预测为属于每个输出类的给最高概率的类标签, 可以将预测概率转化为类值。分类是预测离散类标签的任务, 分类模型将角度划为不同类值, 所预测的角度划入分好的区间, 并对划分的准确度进行评估, 对角度进行了“定性输出”, 模型的性能与 DOA 精度受限于所划分区。回归模型是将输入变量  $x$  的映射函数  $f$  近似为连续输出变量  $y$  的任务。是预测连续数量的任务。对角度进行“定量输出”, 输出连续性变量。显然回归模型更适合 DOA 预测任务。

本文中, 我们可以将问题表述为在给定阵列接收数据时, 估计目标到达角  $\theta$ 。为此, 我们引入了如图 2 所示的模

型处理流程图, 该网络模型以阵列相位差矩阵  $\varphi_M$  为输入, 以 DOA 为输出。




图 2 模型处理流程图

为学习不同环境条件下信号数据与 DOA 之间的映射关系, 并通过模型拟合出信号角度, 在本研究中提出了一个回归网络模型 PhaseDOA-Net。测向系统性能的好坏取决于特征提取的充分程度以及系统学习效率的高低, 故针对测向精度与效率的需求, 通过网络结构模块化的设计优化上述问题。模型的网络结构由一个过滤器大小为  $5 \times 5$  的卷积层和两个模块 IdentifyBlock、FPB (feature pyramid block) 组成。Conv1 是核大小为  $5 \times 5$  卷积层, 允许网络以成本密集型的方式从输入信号阵列中提取低级特征。模块 IdentifyBlock、FPB 被设计用于处理从上层卷积层单元接收到的输出特征图, 通过创建更深层的网络来提取多维纠缠特征, 提高学习效率与性能。在图像问题中, 某个区域在进行卷积运算后得到的特征可能同样存在于其他区域。对一个特征图中的不同区域, 利用其统计学特征来替代该区域的总体特征。利用统计特征代替总体特征的做法可以显著地减少网络参数, 降低运算量, 这种操作被称为池化。由于池化层通过压缩数据与参数量以减少过拟合, 而对于神经网络测向问题来说, 池化操作会造成多路接收信号中细微特征的丢失, 故网络没有使用池化层。网络模型结构如图 3 所示。

图 3 中 IdentifyBlock 用于处理从卷积层中接收到的输出特征图。IdentifyBlock 的原理是通过创建深层次的网络来提取多维纠缠特征, 提高学习效率, 它由两个卷积层组成, 每个卷积层中滤波器个数为 64, 大小为  $3 \times 3$ , 步幅 (Padding) 为 2, 每个卷积层之后是批归一化层 (Batch Normalization, BN) 和修正线性单元层 (ReLU), BN 层加速了网络训练的收敛性, 降低了输入信号的初始化灵敏度, 修正线性单元层定义为  $ReLU(x) = \max(0, x)$ , 解决了正区间梯度消失的问题, 易于计算。随着网络层数的增加, 梯度消失的现象会加重, 且网络训练的效果不会很好, 网络退化等问题严重, 故引入残差网络

结构。在两层或两层以上的节点两端短路连接, 添加了一条“捷径”, 原网络输出的  $F(x)$  就变成了  $F(x) + x$ 。当神经网络无法再学习到高一维度特征时, 该模块的输出变为上一层的输入。这一改动用传统反向传播训练法对深层网络进行训练的收敛速度快, 效果更好<sup>[9]</sup>。

图 3 中 FPB 由两个卷积层组成, 每个卷积层中滤波器个数为 256, 大小为  $3 \times 3$ , 步幅为 1, 在不牺牲特征学习效率的情况下, 显著减少可训练参数的数量和计算成本。在 FPB 中采用相同的残差连通结构, 防止网络深入时消失梯度问题。残差结构中加入一个卷积层, 滤波器个数为 128, 大小为  $1 \times 1$ , 步幅为 1, 此卷积层对特征映射进行线性投影, 通过  $1 \times 1$  的卷积得到与上一层特征层相同的通道数, 发挥了通道级特征对齐和降维的作用。

两个模块线性连接, 通过连接 (串联) 层组合沿深度 (或通道) 维度的所有导出特征。后经过全连接 (full connection, FC) 层与线性 (Linear) 层并输出。FC 层结合了前一层学习到的所有输入特征, 以连接该层中所有预定义的神经元 (或节点)。线性层将特征回归为所期望的信号到达方向角。引入特定模块对输入信号进行特征提取和处理, 提高网络模型的拟合效果, 用所提网络模型自主学习相位差矩阵与 DOA 之间的映射关系; 引入残差网络结构, 解决了卷积神经网络层数加深导致网络退化的问题。

### 2.2 输入数据

对阵列接收数据进行离散傅里叶变换, 即:

$$\mathbf{X}(k) = \sum_{n=0}^{N-1} \mathbf{X}'(n) e^{-j2\pi/Nnk}, \quad 0 \leq k \leq N-1 \quad (10)$$

在频域内通过被测信号所在频点处对应的相位值得到通道相位的估计值, 进而求得各通道相位差的估计值。

对于数据生成, 设定信号源数目  $L = 1$ , 信号频率为 1 200 MHz, 估计接收信号的方向为  $[-35^\circ, 35^\circ]$ , 步长为

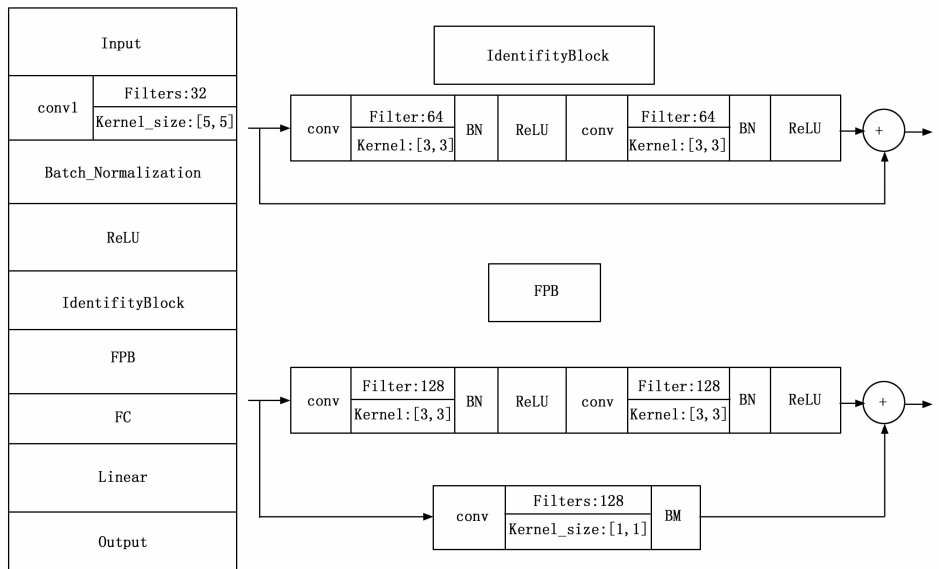


图 3 PhaseDOA-Net 网络结构

0.5°, 信号由间距  $d=0.085$  m, 阵元数  $M=16$  线性阵接收, 快拍数为 1 024。为了尽可能地仿真模拟真实的无线信号环境, 在信号数据中加入高斯白噪声, 信噪比范围  $[-20, 20]$  dB, 步进为 5 dB, 引入相位误差, 范围  $[-20^\circ, 20^\circ]$ , 幅度误差 2 dB, 且服从均匀分布。该数据集包含  $141 \times 9 \times 100$  个信号, 覆盖 141 个 DOA 角度, 9 个不同的信噪比层级, 其中每个信号有 100 个样本, 每个样本由输入数据数组  $I \in \varphi^{2 \times 16}$  组成。数据集被随机分割, 其中 80% 用于训练, 其余的用于测试。

### 2.3 网络训练

网络训练的主要配置如下: 优化器为 Adam 优化器, 最大训练轮数 (epochs) 为 100, 批大小 (Batchsize) 为 1 024, 初始学习率为 0.01, 并设置动态下降学习率 Patience 为 5 (当网络训练的损失值连续 5 个 epochs 不再下降后, 学习率减少 90%, 保证模型在训练后期不会有太大的波动, 从而更加接近最优解, 以实现更好的学习收敛)。数据集的生成和模拟是使用 MATLAB R2016a 完成仿真, 本文提出的深度网络在 Python3.7 中实现和训练。计算服务器具有 Inter Xeon Gold 6 144 CPU 和两个 NVIDIA Quadro RTX 6 000 GPU。

在训练神经网络的过程中, 一般都是先将神经网络前向传播, 在进行反向梯度传播更新参数。在处理多维矩阵数据时, 采用传统的神经网络可能会由于参数过多而无法计算, 而 CNN 通过局部感受野和权值共享减少了参数的数量以及冗余, 简化了网络结构。网络训练过程中将损失函数 (Loss) 设置为均方误差函数 (MSE), 将网络结构输出的  $\theta_{\text{predict}}$  和相应的标签  $\theta_{\text{lable}}$  之间的 MSE 通过最小化目标函数来优化网络参数。

该过程可以用如下公式表示:

$$(W, b) = \min_{w, b} \frac{1}{\text{len}} \|\theta_{\text{lable}} - \theta_{\text{predict}}\|^2 \quad (11)$$

式中, len 为输出层特征长度,  $W$  和  $b$  为神经网络层中各个连接权重与神经元偏置。采用反向传播算法 (error back propagation, BP) 对进行微调。为防止网络训练出现过拟合, 在训练中加入了提前终止算法 (Early Stop), 即模型在测试集上权重的更新低于所设定的阈值, 则提前终止训练, 使用上一次迭代结果中的参数作为训练结果。

损失函数以及所预测 DOA 的均方根误差随训练轮数变化曲线如图 4 所示。在设置了动态下降学习率以及提前终止法后, 初始学习率设置为 0.01 的学习效果最佳, Loss 随训练轮数下降明显, 且回归网络收敛较快。

### 2.4 验证结果

验证集选用的信号方向为  $[-35^\circ, 35^\circ]$ , 步长为  $0.1^\circ$ , 其他条件与训练集相同, 用于对不同算法在均匀阵列条件下 DOA 估计精度对比验证。按照上面描述的算法构建 PhaseDOA-Net 神经网络 DOA 估计模型。DeepMUSIC 测向算法采用文献 [3] 中介绍的方法, 在其他条件




图 4 Loss 及均方根误差随训练轮数变化曲线

相同的情况下对不同方法所测得的 DOA 均方根误差 (RMSE) 进行对比。

DOA 均方根误差随信噪比  $[-20, 20]$  dB 范围变化对比如图 5 (a) 所示。在信噪比  $[0, 20]$  dB 范围内, PhaseDOA-Net 神经网络算法的性能优于 DeepMUSIC 与 MUSIC 算法, 干扰仪算法的 DOA 估计性能最差。如图 5 (b) 所示, 在较高信噪比条件下, 4 种算法的 RMSE 波动不大趋于平稳。DeepMUSIC 的性能损失是由于深度网络中的精度损失所致。这是因为其深层网络作为有偏估计器, 无法提供更加准确的测向结果<sup>[10]</sup>。而 PhaseDOA-Net 神经网络通过增加各个网络层中的单元数、网络层数以及改变网络结构来缓解此问题。

在其他条件不变的情况下, 在训练过程中将输入更改为信噪比为  $[-20, -5]$  dB 数据集, 来观察网络在低信噪比条件下对损坏输入的泛化能力。如图 5 (c) 所示, 可以

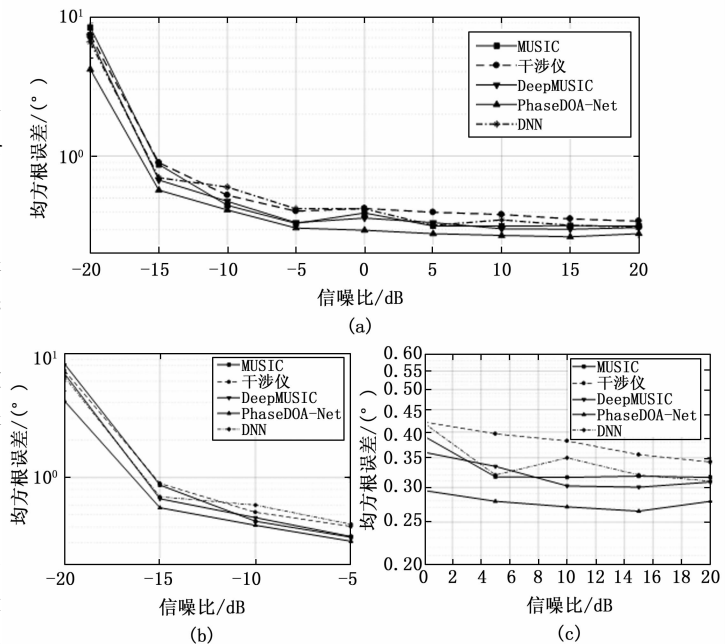


图 5 DOA 测向均方根误差随信噪比变化对比图

看出 PhaseDOA-Net 在低 SNR 情况下 ( $-20$  dB) 的性能优于 MUSIC 算法。MUSIC 算法在低信噪比的条件下噪声子空间与信号子空间划分不准确情况下, 前者与阵列流型导向矢量的正交性会受到影响, 降低 DOA 估计精度。

在提出的 PhaseDOA-Net 中, 所设计的 IdentifyBlock 和 FPB 模块提高了特征学习效率, 提取数据信息并建立有效的映射关系, 提高了模型对不同信号条件的泛化能力, 从而在多个信噪比水平回归拟合出高精度 DOA。PhaseDOA-Net 在不同信噪比水平上优于所有其他模型, 尤其在低信噪比情况下测向精度的提升更加明显。

### 2.5 多频点数据验证

随着无线频谱资源的大规模使用, 甚至大量采用跳频、扩频信号来保证信号的加密传输和抗干扰能力, 故所提模型需适应多种频段的测向需求, 以在多频带场景下使用。

在信噪比 30 dB 的条件下, 将输入信号频率更改为  $[1\ 000, 2\ 000]$  MHz 数据集作为训练集, 其中频率步进为 200 MHz, 共 11 个频点的窄带数据, 每个频点的信号方向集合为  $[-35^\circ, 35^\circ]$ , 步长为  $0.5^\circ$ , 并引入与 2.2 节相同的幅相误差。训练集包含  $141 \times 11 \times 100$  个信号, 覆盖 141 类 DOA 角度, 11 个不同的频率层级, 其中每个信号有 100 个样本。验证集中信号方向集合  $[-35^\circ, 35^\circ]$ , 步长为  $0.1^\circ$ , 其他条件与训练集相同, 计算 DOA 均方根误差来验证网络对输入信号频率的泛化能力。

DOA 预测均方根误差随频率变化对比图如图 6 所示, 可以看出所测信号频率越高, DOA 预测均方根误差越小。所提出的 PhaseDOA-Net 在宽频带 DOA 估计性能优于其他几种测向算法。




图 6 DOA 预测均方根误差随频率变化对比图

### 2.6 测向时间对比

测向时间与算法的计算量相关。对于神经网络模型的计算量可以用浮点运算数 FLOPs (floating-point operations) 来衡量<sup>[11]</sup>。在卷积层中, 采用滑动窗实现卷积且忽略非线性计算开销, 则卷积核的 FLOPs 为:

$$F_{\text{conv}} = 2HW(C_{\text{in}}K^2 + 1)C_{\text{out}} \quad (12)$$

其中:  $H/W$  为输入特征的高度和宽度,  $K$  为核大小,  $C_{\text{in}}$  和  $C_{\text{out}}$  为输入输出通道数。全连接层网络 FLOPs 为:

$$F_{\text{fc}} = (2I - 1)O \quad (13)$$

其中:  $I$  为输入维度,  $O$  为输出维度。

而经典 MUSIC 算法中计算开销主要来源于  $M \times M$  的二阶矩阵计算、矩阵的特征分解以及一维谱峰搜索。在 Python3.7 环境下分别实现 PhaseDOA-Net 与 MUSIC 算法, 经计算 PhaseDOA-Net 的 FLOPs 为 2.47 M, 参数量为 0.18 M, 乘加次数 MAC (multiply accumulate) 是 FLOPs 的一半约为 1.24 M 次, 而 MUSIC 算法的 MAC 约为 2.717 M 次。可以看出 PhaseDOA-Net 模型降低了计算复杂度。

在其他条件不变的情况下, 比较了 PhaseDOA-Net 模型与其他 DOA 估计算法的计算时间。将验证样本数设置为 3 000 个, 样本角度范围为  $[-30^\circ, 30^\circ]$ , 得出各模型算法单个样本 DOA 预测时间如表 1 所示。

表 1 PhaseDOA-Net 与其他算法测向时间对比 ms

算法	PhaseDOA-Net	DeepMUSIC	DNN	相关干涉仪	MUSIC
测向时间	0.953	1.014	0.962	1.829	2.037

由仿真结果可知, 基于 PhaseDOA-Net 模型的 DOA 测向时间低于 MUSIC 与干涉仪算法, 略优于其他智能算法。

## 3 实验结果与分析

### 3.1 暗室环境搭建

本节通过采集实际数据来对比验证网络的 DOA 估计性能。暗室实际采集数据流程图如图 7 所示。发射天线与槽线接收天线间距为 22 米, 符合信号采集远场条件。发射天线采用对轴发射天线。信号源发射单音信号, 发射功率 0 dB。所采信号数据频点范围为 1~2 GHz, 频率步进为 200 MHz。角度范围  $-35^\circ \sim 35^\circ$ , 步进为  $2^\circ$  作为训练与测试数据, 步进  $1^\circ$  作为验证数据。




图 7 暗室实际采集数据流程图

暗室数据采集环境如图 8 所示。接收天线为槽线天线, 阵列形式为均匀线阵, 阵元个数为 6 阵元, 阵元间距为 0.085 m。多通道超短波接收存储单元所存储信号数据为 6 路 I/Q 数据。



图 8 暗室数据采集环境

### 3.2 阵列接收信号误差分析

关于信号和噪声、阵列流型、以及信号处理环境均同时理想的假设,在现实中是较难满足和实现的。尽管信号和噪声条件、阵列条件、以及信号处理时所处需求条件都尽可能地追求理想,但是并不能达到最完美的状态,可能因素包括:

- 1) 噪声干扰、噪声相关性和杂波等环境复杂性的影响;
- 2) 传感器老化、阵元间干扰、以及阵列校正存在误差;
- 3) 信号处理过程需要满足现实应用中的高速度等需求。此时,某种非理想情况的发生,会导致理想条件下提出的 DOA 估计算法受到现实环境和约束的相应影响与干扰,在精度或速度方面无法满足现实需求。通过分析幅相误差阵元位置误差、场地误差和噪声等因素导致的阵列误差,验证智能网络的泛化能力和容错能力。

#### 3.2.1 通道幅相误差

通道误差是影响 DOA 性能的一种重要因素,这里考虑角度独立的通道误差,主要是由于各个通道的传输函数的不一致导致的。由所用多通道超短波接收机的设备技术指标可知,在常温条件下,6 路通道的幅度误差为 1 dB,相位抖动为 2°。

#### 3.2.2 阵元位置误差

由于阵列中阵元的位置存在偏差,引入的不一致性称之为阵元位置误差,阵元位置误差在一般文献中不针对性进行研究,主要是由于阵元位置误差可归结为通道的相位误差<sup>[12-13]</sup>。

假设阵元模型中该阵元的位置被认为是  $d_x$ ,而在实际加工的天线单元上,该阵元的实际位置为  $d_x + \Delta d_x$ ,所以相位误差可表示为:

$$\text{pos\_error} = \frac{2\pi\Delta d_x \sin\theta}{\lambda} \quad (14)$$

由上式可得本系统中接收天线阵元位置造成的相位误差为 3°。

#### 3.2.3 多径效应与信噪比

暗室环境中墙壁由吸波材料填充,大幅减小了多径效应对系统模型的影响,信源与阵列接收器之间不存在任何障碍,直接被阵列接收器接收。通过对环境噪声的测量与对信号发射源发射功率的调整,信噪比保持在 [10 dB, 20 dB] 范围内。

### 3.3 基于实采数据的网络训练与性能验证

在空域角度范围中,把空间角度均匀划分,形成离散角度集合。对于一维阵列,把空域角度范围均匀划分为离散的角度,角度间隔划分过小会增大训练难度,并且使实际采集的工作量急剧增大,而划分过大会降低网络的 DOA 估计精度。实采数据集角度范围设置为 [35°, 35°],间隔为 2°,包含 36 × 11 × 100 个信号,覆盖 36 个 DOA 角度,11 个不同的频率层级,将实际采集存储的 6 路 I/Q 数据进

行数字信号处理。首先对数据进行采样,采样点设为 1 024,得到信号数据  $X^{6 \times 1024}$ ,可得到相位差数据  $\varphi_x$  作为算法训练与验证数据。数据集被随机分割,其中 80% 用于训练,其余的用于测试。

网络训练的主要配置如下:优化器为 Adam 优化器,最大训练轮数 (epochs) 为 80,批大小 (Batchsize) 为 1 024,初始学习率为 0.01,并设置动态下降学习率 Patience 为 5。基于实采数据的深度网络在 Python3.7 中实现和训练。

验证实验一:将验证集中信号频率设置为 1 200 MHz,快拍数为 1 024,信噪比为 15 dB。角度范围设置为 -35° ~ 35°,角度间隔设置为 1°。为了避免实验的偶然结果,采用 100 次蒙特卡洛仿真实验,包含 71 × 100 个信号,覆盖 71 个 DOA 角度。在 100 次蒙特卡洛仿真实验后得到的估计角度与实际角度的平均误差作为最终验证的角度误差结果。

基于实采数据的 DOA 精度验证结果如图 9 所示,图中根据 DOA 真实值与预测值的误差进行对比,查看估计结果与真实位置之间的差距。

上述实验条件下,干涉仪方法的预测结果与真实值的位置差距较大,估计结果与真实角度的差值范围在 0.09 和 0.94 之间,且波动较大,多个位置预测角度严重偏离正确位置,DOA 估计精度较差。通过 MUSIC 方法预测的角度虽然也有部分预测值位置远远偏离真实位置,但对比干涉仪方法,数量上有所减少。DeepMUSIC、DNN 测向误差较传统方法较小,而使用 PhaseDOA-Net 神经网络模型预测的结果误差最小,估计结果与真实角度的差值范围大多集中在 0.02 和 0.47 之间,准确度优于其他方法。

验证实验二:将验证集中信号频率设置为 [1 000, 2 000] MHz,频率步进为 200 MHz,每个频点下快拍数为 1 024。角度范围设置为 -35° ~ 35°,角度间隔设置为 1°,同样采用 100 次蒙特卡洛仿真实验,统计各个频点下 DOA 估计均方根误差,对网络性能进行验证。通过验证得到各算法随频率的均方根误差如图 10 所示。

由图 10 可以观察到,PhaseDOA-Net 网络模型在各个频率范围的 DOA 估计精度均优于其他方法,且频点频率越高,所测得的均方根误差越小,与仿真得出结果一致。

## 4 结束语

针对复杂环境下对高精度快速测向的需求,为解决现有阵列测向体制计算复杂度高、存在阵列误差条件下测向性能恶化严重等问题,开展基于智能方法的高精度测向技术研究。本文提出基于 PhaseDOA-Net 网络模型的高精度快速 DOA 估计算法,提高了低信噪比环境下 DOA 估计方法的鲁棒性,改善了神经网络的泛化能力。通过实际验证比对,所提算法性能在低信噪比环境中不仅优于现有的 MUSIC 算法与相关干涉仪算法,与其他基于深度学习的 DOA 估计算法相比也具有一定优势。而且在阵列误差条件下也表现出了很强的鲁棒性,验证了 PhaseDOA-Net 测向

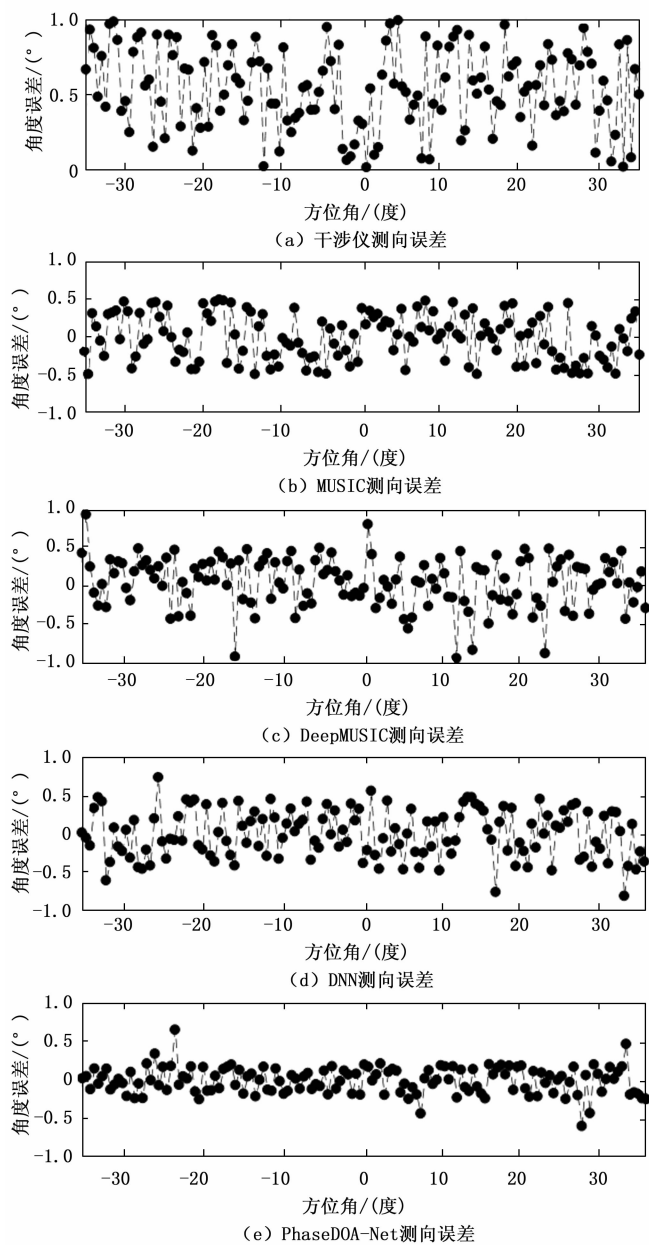


图 9 基于实测数据的 DOA 精度验证结果




图 10 实采信号测向均方根误差随频率变化对比图

方法对阵列误差的泛化能力和容错能力, 在保证测向精度的同时, 在测向时间上也表现出优异的性能。

参考文献:

[1] 管亮中, 杨玉林. 一种快速的空时级联频率—到达角估计 [J]. 电子信息对抗技术, 2016, 31 (1): 1-3.

[2] 段国文, 顾俊杰. 干涉仪测向天线阵列与测向精度关系分析 [J]. 电子信息对抗技术, 2019, 34 (1): 56-60.

[3] ZHU W, ZHANG M. A deep learning architecture for broadband DOA estimation [C] //International Conference on Communication Technology, 2019.

[4] ELBIR A M. DeepMUSIC: Multiple signal classification via deep learning [C] //IEEE International Conference on Communication Systems, 2019.

[5] SHI B, MA X, ZHANG W, et al. Complex-valued convolutional neural networks design and its application on UAV DOA estimation in urban environments [J]. Communications and Information Networks, 2020, 5 (2): 30-137.

[6] HUANG H, YANG J, HUANG H, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system [J]. IEEE Transactionson Vehicular Technology, 2018, 67 (9): 8549-8560.

[7] XIAO P, LIAO B, DELIGIANNIS N. A deep unfolded network for sparse signal recovery from 1-bit measurements with application to DOA estimation [J]. Signal Processing, 2020, 176.

[8] 翁元博, 徐 湛, 田 露, 等. 基于 GRNN 的相干信源 DOA 估计方法 [J]. 北京信息科技大学学报, 2021, 36 (4): 66-75.

[9] 郭玥秀, 杨 伟, 刘 琦, 等. 残差网络研究综述 [J]. 计算机应用研究, 2020, 37 (5): 1292-1297.

[10] 张永皓, 苏雪嫣, 胡 蝶. 一种基于深度学习的环形阵列混合波束成型大规模 MIMO 系统 DOA 估计算法 [J]. 微型电脑应用, 2020, 36 (11): 1-4.

[11] LI Q, ZHANG X, Li H. Online direction of arrival estimation based on deep learning [C] // IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2018.

[12] 郭业才, 侯 坤. 基于稀疏堆叠降噪自编码器—深层神经网络的语音 DOA 估计算法 [J]. 实验室研究与探索, 2021, 40 (3): 1-13.

[13] 郭业才, 刘力玮. 基于 ResNet 的稳健语音 DOA 估计算法 [J]. 数据采集与处理, 2019, 34 (5): 789-796.

[14] 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.

[15] 李 川. 干涉仪测向体制误差性能分析 [J]. 电子测量技术, 2011, 34 (6): 114-117.

[16] 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 Communication, 2016, 23 (8): 1091-1095.

(下转第 29 页)