

DOI:10.3969/j.issn.1003-5060.2024.01.007

# 基于深度复数神经网络的雷达目标 DOA 估计算法

朱安琪<sup>1</sup>, 项厚宏<sup>2</sup>, 齐美彬<sup>2</sup>

(1. 合肥工业大学 机械工程学院, 安徽 合肥 230009; 2. 合肥工业大学 计算机与信息学院, 安徽 合肥 230601)

**摘要:**传统模型驱动的波达方向(direction of arrival, DOA)估计算法性能受限于有限的信号特征、快拍数、信噪比、信杂比等因素,在低信噪比、快拍数少的极端情况下,性能较差。为克服上述问题,提高在极端条件下的估计精度,文章提出基于深度复数神经网络(complex-valued neural networks, CVNN)的单快拍 DOA 估计算法,构建深度复数神经网络模型,学习原始带噪信号与理想无噪复信号之间的映射关系,进而实现噪声抑制和期望信号特征增强的目的,提高 DOA 估计精度。仿真实验结果表明,经 CVNN 增强后,数据的等效信噪比约提高了 1 dB,等效快拍数提高了 3,该文所提算法相较于已有的多种物理驱动算法而言,具有更高的估计精度和泛化性。

**关键词:**波达方向(DOA)估计;深度复数神经网络(CVNN);数据驱动;模型驱动

**中图分类号:**TN958.92 **文献标志码:**A **文章编号:**1003-5060(2024)01-0041-06

## DOA estimation algorithm based on complex-valued neural networks

ZHU Anqi<sup>1</sup>, XIANG Houhong<sup>2</sup>, QI Meibin<sup>2</sup>

(1. School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China; 2. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China)

**Abstract:** The performance of traditional model-driven direction of arrival(DOA) estimation algorithm is limited by the finite signal characteristics, number of snapshots, signal-to-noise ratio(SNR), signal-to-heterodyne ratio and other factors, and the algorithm performance is poor in the extreme cases of low SNR and few snapshots. To overcome the above problems and improve the estimation accuracy under extreme conditions, this paper proposes a single snapshot DOA estimation algorithm based on complex-valued neural networks(CVNN), which constructs a deep complex network model to learn the mapping relationship between the original noisy signal and the ideal noise-free complex signal, and then achieves noise suppression and desired signal feature enhancement. The proposed algorithm is used to improve the accuracy of DOA estimation. Simulation results show that after CVNN enhancement, the equivalent SNR of the data is improved by about 1 dB, and the equivalent number of snapshots is improved by 3, the proposed algorithm has higher estimation accuracy and generalization than the existing multiple algorithms driven by physics.

**Key words:** direction of arrival(DOA) estimation; complex-valued neural networks(CVNN); data driven; model driven

波达方向(direction of arrival, DOA)估计在雷达、通信、宇航等领域有着广泛的应用,且是阵列信号处理的重要研究方向<sup>[1]</sup>。在雷达阵列信号

处理领域中,经典有效的物理模型驱动算法包括多重信号分类算法(multiple signal classification, MUSIC)<sup>[2]</sup>、最大似然估计算法(maximum

收稿日期:2022-12-09;修回日期:2023-02-22

基金项目:国家自然科学基金资助项目(62201189);安徽省重大基础研究资助项目(2023z04020018)和中央高校基本科研业务费专项资金资助项目(JZ2022HGTA0347)

作者简介:朱安琪(1997—),女,安徽安庆人,合肥工业大学硕士生;

项厚宏(1994—),男,安徽安庆人,博士,合肥工业大学讲师,通信作者,E-mail:hhxiang@hfut.edu.cn;

齐美彬(1969—),男,安徽安庆人,博士,合肥工业大学教授,博士生导师。

likelihood, ML)<sup>[3]</sup>、旋转不变子空间算法(estimation of signal parameter via rotational invariance techniques, ESPRIT)<sup>[4]</sup>和以贝叶斯学习的稀疏感知算法<sup>[5-6]</sup>等。物理模型均是在一定先验条件下得到,如入射信号满足远场、近场或混合场等物理条件<sup>[7-8]</sup>,在不同的条件下,各算法的估计表达式又存在较大不同,而且当阵列存在多种非理想因素(如阵列误差等)时,物理驱动的算法估计性能会急剧下降,甚至无法准确估计。

随着深度学习技术在信号处理领域的广泛应用,基于深度神经网络的数据驱动的 DOA 估计算法也在持续推进。目前数据驱动的 DOA 估计算法主要分为 3 大类:第 1 类是端到端的 DOA 估计算法<sup>[9-11]</sup>,将 DOA 估计问题建模成高维非线性映射模型,直接学习阵列接收数据与 DOA 的映射关系,进而实现 DOA 估计,此类学习模型简单,直接从阵列接收数据中挖掘 DOA 信息,但缺少应用阵列先验信息(如方位、地形等),阵地适应性一般;第 2 类是将 DOA 估计问题建模成分类问题<sup>[12-13]</sup>,由于 DOA 信息具有空域稀疏性,将 DOA 信息构造独热编码形式,通过学习阵列接收数据到 DOA 的分类网络,从而实现 DOA 估计,虽然分类模型比较成熟,但是 DOA 估计问题本质上是回归问题,若以一定的角度将整个空域划分成多个标签,则必然会存在细微的模型误差,测角性能受限于划分角度;第 3 类是重点考虑阵列接收数据中的相位特征<sup>[14-16]</sup>,通过增强期望信号的相位特征,实现期望信号增强,非期望信号抑制的效果,进而提高 DOA 估计精度。这 3 类深度学习的 DOA 估计算法均训练阵列接收的复数据的部分实数特征或者实数化,对于复数域的线性映射模型来说<sup>[17-18]</sup>,学习部分实数特征或者实数化处理复数据显然不能有效学习全域特征或者增大学习复杂度。

本文构建复数域的神经网络模型,学习阵列接收带噪复数据与理想无噪的标签数据的映射关系,实现期望信号特征增强和非期望信号削弱的效果,最后利用经典的物理驱动算法数字波束形成(digital beam forming, DBF)和多重信号分类算法(multiple signal classification, MUSIC)算法进行 DOA 估计。

## 1 信号模型

假设阵列结构为  $M$  阵元的均匀线阵,阵元间距为  $d$ ,  $K$  个相互独立的远场窄带入射信号

$\mathbf{s}(t)=[s_1(t) \ s_2(t) \ \cdots \ s_K(t)]^T$ ,其方向向量  $\boldsymbol{\theta}=[\theta_1 \ \theta_2 \ \cdots \ \theta_K]^T$ ,信号波长  $\lambda$ ,则阵列在  $t$  时刻的数据  $\mathbf{y}(t)=[y_1(t) \ y_2(t) \ \cdots \ y_M(t)]^T$  可表示为:

$$\mathbf{y}(t) = \sum_{k=1}^K \mathbf{a}(\theta_k) s_k(t) + \mathbf{n}(t), \quad t = 1, 2, \dots, L \quad (1)$$

其中:阵列导向向量  $\mathbf{a}(\theta_k)=[1 \ \exp(-j2\pi/\lambda d \sin(\theta_k)) \ \cdots \ \exp(-j(M-1)2\pi/\lambda d \sin(\theta_k))]^T$ ;  $\mathbf{n}(t)=[n_1(t) \ n_2(t) \ \cdots \ n_M(t)]^T$  为均值为 0、功率为  $\sigma_n^2$  的复高斯白噪声;  $L$  为快拍数。对于独立的高斯白噪声,则有:

$$E(\mathbf{n}(t_i), \mathbf{n}(t_j)) = \sigma_n^2 \mathbf{I} \delta_{t_i, t_j} \quad (2)$$

其中:  $\mathbf{I}$  表示单位矩阵;  $\delta_{t_i, t_j}$  表示冲激函数。且信号源与噪声互不相关,即

$$E(\mathbf{n}(t_i), \mathbf{s}(t_j)) = 0 \quad (3)$$

假设信号源之间互不相关,则有:

$$E(\mathbf{s}(t_i) \mathbf{s}^H(t_j)) = \text{diag}(\mathbf{p}) \delta_{t_i, t_j} \quad (4)$$

其中:  $\mathbf{p}=[p_1 \ p_2 \ \cdots \ p_K]^T$  为  $K$  个信号源的功率矢量。当阵列接收到  $L$  个快拍数据时,阵列接收数据记为  $\mathbf{Y}=[\mathbf{y}(t_1) \ \mathbf{y}(t_2) \ \cdots \ \mathbf{y}(t_L)] \in \mathbf{C}^{M \times L}$ ,信源数据记为  $\mathbf{S}=[\mathbf{s}(t_1) \ \mathbf{s}(t_2) \ \cdots \ \mathbf{s}(t_L)] \in \mathbf{C}^{K \times L}$ ,噪声数据记为  $\mathbf{N}=[\mathbf{n}(t_1) \ \mathbf{n}(t_2) \ \cdots \ \mathbf{n}(t_L)] \in \mathbf{C}^{M \times L}$  多快拍条件下,阵列接收数据模型可以表示为:

$$\mathbf{Y} = \mathbf{AS} + \mathbf{N} \quad (5)$$

阵列接收数据协方差矩阵为:

$$\mathbf{R} = E(\mathbf{Y}\mathbf{Y}^H) = \mathbf{A} \text{diag}(\mathbf{p}) \mathbf{A}^H + \sigma_n^2 \mathbf{I}_M \quad (6)$$

在实际工程中,数据协方差矩阵以采样协方差矩阵代替,即

$$\hat{\mathbf{R}} = \frac{1}{L} \sum_{l=1}^L \mathbf{y}(t_l) \mathbf{y}^H(t_l) \quad (7)$$

因此,阵列接收数据协方差矩阵  $\mathbf{R}$  与实际采样协方差矩阵  $\hat{\mathbf{R}}$  存在一定的误差  $\Delta \mathbf{R}$ :

$$\mathbf{R} = \hat{\mathbf{R}} + \Delta \mathbf{R} \quad (8)$$

已有的物理驱动的超分辨 DOA 估计算法有 DBF 算法、MUSIC 算法和 ML 算法,其估计表达式可总结为:

$$\hat{\theta}_{\text{DBF}} = \underset{\theta}{\text{argmax}} \mathbf{a}^H(\theta) \mathbf{R} \mathbf{a}(\theta) \quad (9)$$

$$\hat{\theta}_{\text{MUSIC}} = \underset{\theta}{\text{argmax}} \mathbf{a}^H(\theta) \mathbf{U}_N \mathbf{U}_N^H \mathbf{a}(\theta) \quad (10)$$

$$\hat{\theta}_{\text{ML}} = \underset{\theta}{\text{argmax}} \text{tr}[\mathbf{P}_{\mathbf{A}(\theta)} \mathbf{R}] \quad (11)$$

其中:  $\mathbf{U}_N$  为噪声子空间;  $\mathbf{P}_{\mathbf{A}(\theta)}$  为投影到阵列流型矩阵  $\mathbf{A}(\theta)$  张成的信号空间的投影算子。通过搜索,实现对目标角度的估计。根据 3 个算法的估

计表达式,消除协方差矩阵误差和噪声数据协方差矩阵,才能有效提高期望信号的信噪比,提高 DOA 估计算法精度。观察阵列接收数据模型,阵列接收数据  $\mathbf{y}(t)$  为  $K$  个阵列导向向量的线性组合,目标角度  $\theta$  或  $\mathbf{a}(\theta)$  与阵列输出数据  $\mathbf{y}(t)$  为线性映射关系。

若采用复数神经网络 (complex-valued neural networks, CVNN), 则能极大减小学习难度且更有效,因此本文提出一种基于复数神经网络的 DOA 估计算法,通过构建复数神经网络,增强期望信号数据,削弱噪声等非期望信号,最后采用经典的超分辨算法实现 DOA 估计。

## 2 复数神经网络的 DOA 估计算法

本文提出的复数神经网络的 DOA 估计算法系统框图如图 1 所示。在训练部分,对阵列接收数据进行归一化预处理,并构建复数神经网络,通过大量多快拍数据,学习阵列接收到的单个快拍数据与理想无噪数据的映射关系。在增强部分,首先结合训练部分的归一化参数对测试数据进行归一化预处理;然后输入训练好的复数神经网络,并用归一化参数对输出数据进行反归一化预处理,得到增强后的阵列数据;最后采用已有的物理驱动算法进行 DOA 估计。




图 1 基于复数神经网络特征增强的 DOA 估计算法框图

### 2.1 复归一化预处理

实际阵列采集数据的信噪比随着目标的空间状态、位置的改变而存在较大起伏,其直接表现在脉压后数据的实虚部值变化较大,因此在特征提出过程中,输入特征变化较大导致协变量偏移现象。复归一化预处理是输入复数神经网络前的一次预处理,利用优化改变方差大小和均值位置,使得新的分布更契合数据的真实分布,保证模型的非线性表达能力。复归一化预处理算法将实部和虚部分开,分别看成 2 个不同维度,具体计算公式为:

$$\tilde{\mathbf{x}} = \mathbf{C}^{-\frac{1}{2}}(\mathbf{x} - E[\mathbf{x}]) \quad (12)$$

其中:  $\mathbf{x}$  和  $\tilde{\mathbf{x}}$  分别为原始复数数据和归一化预处理

后的复数数据;  $E[\mathbf{x}]$  代表复数数据的期望;  $\mathbf{C}$  为维度为  $2 \times 2$  的协方差矩阵,即

$$\mathbf{C} = \begin{bmatrix} c_{rr} & c_{ri} \\ c_{ir} & c_{ii} \end{bmatrix} = \begin{bmatrix} \text{cov}(\text{Re}(\mathbf{x}), \text{Re}(\mathbf{x})) & \text{cov}(\text{Re}(\mathbf{x}), \text{Im}(\mathbf{x})) \\ \text{cov}(\text{Im}(\mathbf{x}), \text{Re}(\mathbf{x})) & \text{cov}(\text{Im}(\mathbf{x}), \text{Im}(\mathbf{x})) \end{bmatrix} \quad (13)$$

其中:  $c_{rr}$ 、 $c_{ri}$ 、 $c_{ir}$  和  $c_{ii}$  代表矩阵的 4 个分量。归一化后的复数数据  $\tilde{\mathbf{x}}$  的均值  $\boldsymbol{\mu}_{\tilde{\mathbf{x}}}$ 、协方差矩阵  $\boldsymbol{\Gamma}_{\tilde{\mathbf{x}}}$  和伪协方差矩阵  $\mathbf{B}_{\tilde{\mathbf{x}}}$  分别为:

$$\boldsymbol{\mu}_{\tilde{\mathbf{x}}} = E[\tilde{\mathbf{x}}] \quad (14)$$

$$\boldsymbol{\Gamma}_{\tilde{\mathbf{x}}} = E[(\tilde{\mathbf{x}} - \boldsymbol{\mu}_{\tilde{\mathbf{x}}})(\tilde{\mathbf{x}} - \boldsymbol{\mu}_{\tilde{\mathbf{x}}})^*] = c_{rr} + c_{ii} + j(c_{ir} - c_{ri}) \quad (15)$$

$$\mathbf{B}_{\tilde{\mathbf{x}}} = E[(\tilde{\mathbf{x}} - \boldsymbol{\mu}_{\tilde{\mathbf{x}}})(\tilde{\mathbf{x}} - \boldsymbol{\mu}_{\tilde{\mathbf{x}}})] = c_{rr} - c_{ii} + j(c_{ir} + c_{ri}) \quad (16)$$

由式(12)可知,  $\tilde{\mathbf{x}}$  符合标准的复高斯分布,即  $\boldsymbol{\mu}_{\tilde{\mathbf{x}}} = \mathbf{0}$ 、 $\boldsymbol{\Gamma}_{\tilde{\mathbf{x}}} = \mathbf{1}$  和  $\mathbf{B}_{\tilde{\mathbf{x}}} = \mathbf{1}$ 。

### 2.2 复前向传播

对于复归一化预处理后的输入数据,采用栈式神经网络模型,即每个隐含层均与前一层的神经元相连接,做线性处理和非线性激活后输出。对于第  $q$  层复数神经网络,其网络的输出可以表示为:

$$\mathbf{o}_q = \begin{cases} f(\mathbf{W}_q \mathbf{o}_{q-1} + \mathbf{b}_q), & q = 1, 2, \dots, Q-1; \\ \mathbf{W}_q \mathbf{o}_{q-1} + \mathbf{b}_q, & q = Q \end{cases} \quad (17)$$

其中:  $\mathbf{o}_q$  和  $\mathbf{o}_{q-1}$  分别表示第  $q$  层的输出和输入数据,且  $\mathbf{o}_0$  为复数神经网络的输入;  $\mathbf{W}_q$  和  $\mathbf{b}_q$  分别表示第  $q$  层的复权值矩阵和复偏置矢量;  $f(x)$  表示复激活函数,直接决定反向传播 (backpropagation, BP) 算法的非线性拟合性能和收敛性。

通常,复激活函数是可解析和有界,即需要满足柯西-黎曼方程。现有研究中常用的复激活函数有 Csigmoid、Ctanh、modReLU、zReLU 和 CReLU 等,已有文献验证了 CReLU 不仅满足柯西-黎曼方程,而且非线性映射性能更优,在网络层数较多的情况下,能够尽可能地保留更多的有用信息。因此,本文采用 CReLU 复激活函数,其等价于采用 ReLU 激活函数分别处理实部和虚部,其计算表达式为:

$$\text{CReLU}(\mathbf{x}) = \text{ReLU}(\text{Re}(\mathbf{x})) + j\text{ReLU}(\text{Im}(\mathbf{x})) \quad (18)$$

### 2.3 CVNN 的复反向传播与参数更新

CVNN 的监督训练时优化复权矩阵和复偏置矢量,使得网络输出与标签值相匹配,本文采用复均方误差 (complex mean square error, CMSE)

为损失函数,其定义方式为:

$$E_{\text{CMS}} = \frac{1}{2D} \sum_{d=1}^D \|\boldsymbol{\sigma}^d - \hat{\boldsymbol{\sigma}}^d\|^2 \quad (19)$$

其中: $\boldsymbol{\sigma}^d$  和  $\hat{\boldsymbol{\sigma}}^d$  分别表示第  $d$  个样本的网络输出及其标签。

通过最小化 CMSE,优化、更新复数神经网络的复权矩阵和复偏置矢量,即

$$(\mathbf{W}, \mathbf{b}) = \min_{\mathbf{w}, \mathbf{b}} E_{\text{CMS}} \quad (20)$$

本文采用随机梯度下降算法更新网络的复权矩阵和复偏置矢量,其迭代过程可以表示为:

$$\begin{cases} \mathbf{v}\mathbf{W}_{t+1} = \mu\mathbf{v}\mathbf{W}_t - \eta d\mathbf{W}, \\ \mathbf{W} = \mathbf{W} - \mu\mathbf{v}\mathbf{W} + (1 + \mu)\mathbf{v}\mathbf{W}_{t+1} \end{cases} \quad (21)$$

$$\begin{cases} \mathbf{v}\mathbf{b}_{t+1} = \mu\mathbf{v}\mathbf{b}_t - \eta d\mathbf{b}, \\ \mathbf{b} = \mathbf{b} - \mu\mathbf{v}\mathbf{b} + (1 + \mu)\mathbf{v}\mathbf{b}_{t+1} \end{cases} \quad (22)$$

其中: $\mathbf{v}\mathbf{W}_{t+1}$  和  $\mathbf{v}\mathbf{W}_t$  分别表示  $t+1$  次和  $t$  次的复值权重的速度矢量,初始状态为  $\mathbf{0}$ ;  $\mathbf{v}\mathbf{b}_{t+1}$  和  $\mathbf{v}\mathbf{b}_t$  分别表示  $t+1$  次和  $t$  次的复值偏置矢量的速度矢量,初始状态为  $\mathbf{0}$ ;  $\mu \in [0, 1]$  表示动量常数;  $\eta$  表示学习率;  $d\mathbf{W}$  和  $d\mathbf{b}$  分别表示复权矩阵和复偏置矢量的梯度。

在增强部分,考虑实际雷达接收数据是多快拍数据,对单个快拍数据进行增强处理后再合成,最后采用已有的物理驱动算法进行 DOA 估计。对于  $t_i$  时刻快拍数据  $\mathbf{y}(t_i)$ ,采用式(12)对  $\mathbf{y}(t_i)$  进行复归一化预处理,并输入至训练好的复数神经网络,其输出记为  $\mathbf{y}'(t_i)$ ;根据式(7)计算得到增强后的采样协方差矩阵,记为  $\hat{\mathbf{R}}'$ ;采用式(9)~(11)对采样协方差矩阵  $\hat{\mathbf{R}}'$  进行 DOA 估计。

### 3 实验仿真和分析

本节通过计算机仿真实验,分析不同信噪比和快拍数下所提算法的估计精度及泛化性。假设阵列接收为 15 阵元的均匀线阵,阵元间距半波长,批大小为 100,学习率为  $10^{-5}$ ,动量常数为 0.9。假设存在 2 个相干源,  $\theta_1 \in [-3^\circ, 0^\circ]$ ,  $\theta_2 \in [5^\circ, 8^\circ]$ ,此时 1 个波束宽度以内和 1 个波束以外均存在样本,保证样本的多样性。本文对比 CVNN 增强前后各算法的测角均方根误差(root mean square error, RMSE),展示增强前后的空间谱,分析所提算法的有效性和可靠性。测角均方根误差定义公式为:

$$\theta_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\theta_i - \hat{\theta}_i)^2} \quad (23)$$

其中: $N$  为蒙特卡洛实验次数;  $\theta_i$  和  $\hat{\theta}_i$  分别为第  $i$  次实验处理角度和真实角度。

#### 3.1 信噪比对估计精度的影响

设快拍数为 10,训练集样本的信噪比为 0~10 dB,信噪比间隔为 2 dB;测试集样本的信噪比与训练集样本完全匹配。以蒙特卡洛方法生成样本,训练集的蒙特卡洛次数为  $10^5$ ,测试集的蒙特卡洛次数为  $2 \times 10^3$ 。DBF、MUSIC 和 ML 算法在 CVNN 增强前、后的测角均方根误差与信噪比的关系曲线如图 2 所示。

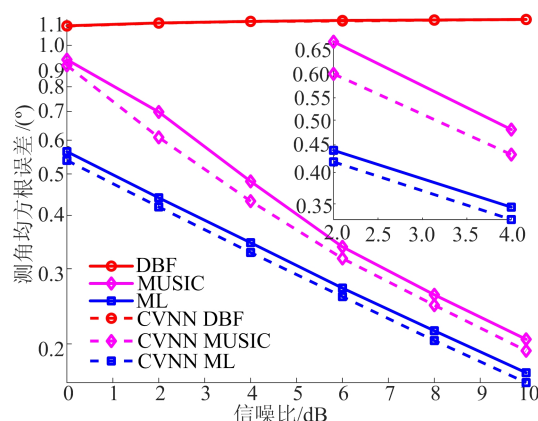




图 2 测角均方根误差与信噪比关系曲线

从图 2 可以看出:DBF 算法在增强前、后性能均较差,不能准确测角,这是由于  $\theta_1$  和  $\theta_2$  在一个波束宽度内,而 DBF 不能突破瑞利线;而增强后的 MUSIC 算法和 ML 算法的效果更优,误差更小。


以 ML 算法为分析对象,若以信噪比为参考指标,经过 CVNN 增强后,随着信噪比的增大,测角均方根误差由  $0.53^\circ$  下降至  $0.16^\circ$ ,其接收数据的等效信噪比约提高了 1 dB。随机抽取一个样本,信噪比在 0~10 dB 时的 MUSIC 空间谱分析结果如图 3 所示。



(a) 信噪比为 0 dB




(b) 信噪比为 2 dB




(f) 信噪比为 10 dB

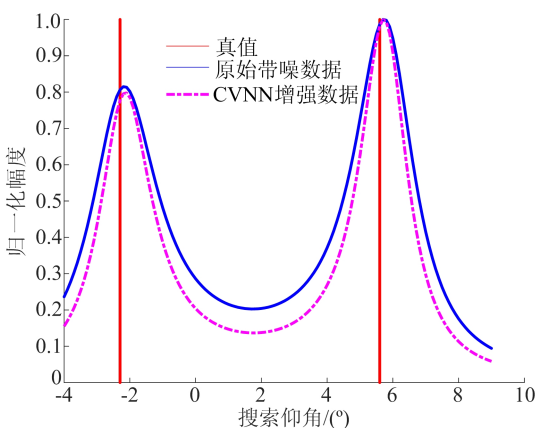
图 3 MUSIC 算法空间谱分析



(c) 信噪比为 4 dB



(d) 信噪比为 6 dB



(e) 信噪比为 8 dB

从图 3 可以看出,信噪比越大, MUSIC 算法空间谱的谱峰越尖锐,测角误差越小,且经过 CVNN 增强后, MUSIC 算法的谱峰更尖锐,且测角误差更小。因此,本文算法在匹配信噪比条件下测角性能更佳,且具有良好的噪声抑制能力。

### 3.2 算法对信噪比的泛化性

本节分析算法对信噪比参数的泛化性,即训练集和测试集样本的信噪比不完全匹配时,所提算法的测角精度。本节的仿真参数与 3.1 节保持一致,但测试集的信噪比范围为  $-1 \sim 13$  dB,与训练集样本的信噪比差异始终存在 1 dB 以上的差异。不同信噪比条件下所提算法的估计精度如图 4 所示。




图 4 所提算法对信噪比的泛化性分析

由图 4 可知,即使训练集和测试集信噪比参数不完全匹配,所提算法仍然可以有效测角,且测角性能较已有算法有所提升。以 ML 算法作为分析对象,随着信噪比的增大,测角均方根误差由  $0.6^\circ$  下降至  $0.11^\circ$ 。综合分析结果可知,所提算法具有良好的估计性能和泛化性。

### 3.3 快拍数对估计精度的影响

本节分析快拍数对所提算法性能的影响。阵列结构参数与上述各节一致,训练集和测试集的信噪比均为 0 dB,测试集的快拍数为 10~25,不同快拍数的测角均方根误差如图 5 所示。

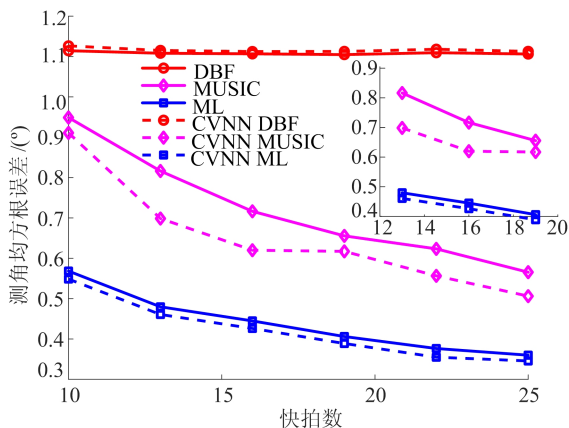


图 5 测角均方根误差与快拍数的关系

由图 5 可知:经过 CVNN 增强后,ML 算法的测角误差由  $0.54^\circ$  下降至  $0.34^\circ$ ;MUSIC 算法的测角误差由  $0.91^\circ$  下降至  $0.51^\circ$ 。算法性能均优于增强前的各类算法。若以快拍数作为评价指标,经过 CVNN 增强后,数据的等效快拍数提高了 3。因此,所提算法适用于多快拍场景,且性能较优。

## 4 结 论

本文提出了一种基于 CVNN 的目标 DOA 估计算法,通过构建复数神经网络,直接训练阵列接收复数据,实现期望信号增强和非期望信号抑制的效果,进而提高 DOA 估计精度。大量仿真实验表明,经过 CVNN 增强后,传统算法的估计效果有一定的提升,模型可解释性更强。

### [参 考 文 献]

[1] ZHANG J A, LIU F, MASOUIROS C, et al. An overview of signal processing techniques for joint communication and radar sensing[J]. IEEE Journal of Selected Topics in Signal Processing, 2021, 15(6): 1295-1315.

[2] SCHMIDT R. Multiple emitter location and signal parameter estimation[J]. IEEE Transactions on Antennas and Propagation, 1986, 34(3): 276-280.

[3] JAFFER A G. Maximum likelihood direction finding of stochastic sources: a separable solution [C]//International Conference on Acoustics, Speech, and Signal Processing. [S. l. : s. n. ], 1988: 2893-2896.

[4] LIN J C, MA X C, YAN S G, et al. Time-frequency multi-invariance esprit for DOA estimation[J]. IEEE Antennas

and Wireless Propagation Letters, 2016, 15: 770-773.

[5] CHEN P, CAO Z X, CHEN Z M, et al. Off-grid DOA estimation using sparse Bayesian learning in MIMO radar with unknown mutual coupling[J]. IEEE Transactions on Signal Processing, 2019, 67(1): 208-220.

[6] WAN J, WANG C C, SHEN P, et al. Robust and fast super-resolution SAR tomography of forests based on covariance vector sparse Bayesian learning[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.

[7] 秦宇楠,孙晓颖,刘国红. 基于协方差差分的近场源定位参量估计[J]. 电子学报, 2021, 49(1): 177-182.

[8] 蒋佳佳,段发阶,陈劲,等. 一种高精度的近场与远场混合源定位算法[J]. 天津大学学报(自然科学与工程技术版), 2013, 46(12): 1114-1121.

[9] LIU Z M, ZHANG C, 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.

[10] XIANG H H, CHEN B X, YANG M L, et al. Altitude measurement based on characteristics reversal by deep neural network for VHF radar[J]. IET Radar, Sonar Navigation, 2019, 13(1): 98-103.

[11] WU L L, HUANG Z T. Coherent SVR learning for wide-band direction-of-arrival estimation [J]. IEEE Signal Processing Letters, 2019, 26(4): 642-646.

[12] 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.

[13] ZOOGHBY A H, CHRISTODOULOU C G, GEORGIOPOULOS M. A neural network-based smart antenna for multiple source tracking [J]. IEEE Transactions on Antennas and Propagation, 2000, 48(5): 768-776.

[14] XIANG H H, CHEN B X, YANG M L, et al. A novel phase enhancement method for low-angle estimation based on supervised DNN learning[J]. IEEE Access, 2019, 7: 82329-82336.

[15] XIANG H H, CHEN B X, YANG T, et al. Improved demultipath neural network models with self-paced feature-to-feature learning for DOA estimation in multipath environment [J]. IEEE Transactions on Vehicular Technology, 2020, 69(5): 5068-5078.

[16] XIANG H H, CHEN B X, YANG M L, et al. Angle separation learning for coherent DOA estimation with deep sparse prior [J]. IEEE Communications Letters, 2021, 25(2): 465-469.

[17] 马贤. 基于复数网络的辐射源识别及 HLS 实现[D]. 成都: 电子科技大学, 2022.

[18] 张云,化青龙,姜义成,等. 基于混合型复数域卷积神经网络的三维转动舰船目标识别[J]. 电子学报, 2022, 50(5): 1042-1049.