

基于多特征融合的阵列孔径扩展学习方法

张玉涛¹ 张志武¹ 韩天水² 郭恩远² 韩圣千² 孙进平²

(1. 中国船舶集团有限公司第八研究院 南京 211153; 2. 北京航空航天大学电子信息工程学院 北京 100191)

摘 要: 到达角(DOA)估计是阵列信号处理领域的一个重要研究方向,其估计精度与阵列孔径密切相关。增大阵列孔径可以有效提升 DOA 估计性能,但传统方法通常采用增加阵元数量的方式来扩展孔径,在实际应用中受到物理尺寸和硬件成本的限制。因此,如何在增加物理资源的情况下有效扩展阵列孔径是值得研究的问题。本研究提出一种基于多特征融合的阵列孔径扩展学习方法,首先通过多尺度卷积模块提取小孔径阵列接收信号的特征,然后结合通道注意力模块对多特征进行自适应加权融合,最终生成大孔径阵列接收信号。仿真结果表明,所提出的方法能够基于单个快照的小孔径阵列信号有效实现孔径扩展,显著提升 DOA 估计性能。

关键词: 阵列孔径扩展;深度学习;到达角估计;深度神经网络

中图分类号: TN92 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Multi-feature fusion based learning method for array aperture expansion

Zhang Yutao¹ Zhang Zhiwu¹ Han Tianshui² Guo Siyuan² Han Shengqian² Sun Jinping²

(1. The Eighth Research Academy of CSSC, Nanjing 211153, China;

2. School of Electronics and Information Engineering, Beihang University, Beijing 100191, China)

Abstract: Direction of arrival (DOA) estimation is an important research area in array signal processing, where estimation accuracy is closely related to the array aperture. Increasing the array aperture can effectively improve DOA estimation performance. However, traditional methods usually rely on increasing the number of array elements to expand the aperture, which is limited by physical size and hardware costs in practical applications. Therefore, effective expansion of array aperture without increasing physical resources is worth studying. This paper proposes a multi-feature fusion based learning method for array aperture expansion. By employing a multi-scale convolution module to extract features from the received signals of a small-aperture array, and combining it with a channel attention module for adaptive weighted fusion of multiple features, the proposed method ultimately generates received signals of a larger-aperture array. Simulation results show that the proposed method can expand the array aperture based on single snapshot signal of small aperture array and significantly improves DOA estimation performance.

Keywords: aperture expansion; DOA estimation; deep learning; deep neural network

0 引 言

到达角(direction of arrival, DOA)估计在通信、雷达等多个领域发挥着重要作用^[1-4]。DOA 估计精度与阵列孔径尺寸密切相关,增大阵列孔径可以有效提高角度分辨率,增强对信号源方向的辨识能力。传统阵列孔径扩展方法,如 Fishler 等^[5]提出的多输入多输出阵列、牟仕林^[6]提出的稀疏线性阵列和 Bilik 等^[7]提出的阵列级联等,通常需要增加物理阵元数量,在实际应用中受到硬件成本和阵列尺寸的限制。为此,已有文献提出了虚拟阵列孔径扩展技术,通过引入虚拟阵元,在不增加物理尺寸的情况下扩展孔径,为提

升 DOA 估计性能提供了新思路。

Dogan 等^[8]提出了一种基于高阶累积量的阵列扩展方法,通过产生虚拟阵元来增大孔径。Chevalier 等^[9]分析了四阶累积量在 DOA 估计中的应用,发现其代数结构与二阶累积量的协方差矩阵具有相似性,因此包含 M 个阵元的均匀线阵可通过高阶累积量方法扩展为包含 $2M - 1$ 个虚拟阵元的均匀线阵。该方法获取高阶累积量需要高阶矩阵伪逆运算,计算复杂度高,实时性较差。Friedlander 等^[10]提出的阵列内插法是另一种常见的阵列孔径扩展技术,通过构造映射矩阵来提升阵列导向向量的维度。Cui 等^[11]提出了在稀疏阵列中插入虚拟阵元来填补缺失的阵元位置,

从而将稀疏阵列转化为均匀线阵。Hyberg 等^[12]采用该方法将圆形阵列转化为阵元间距为半波长的均匀线阵,提高了 DOA 估计精度。然而,阵列内插法在实际应用中存在一定的局限性。当虚拟阵列孔径超出实际阵列的孔径时,映射矩阵将协方差矩阵中的白噪声转化为色噪声,降低 DOA 估计精度。虽然预白化技术可以在一定程度上改善噪声色化问题,使得噪声的频谱特性更接近于白噪声,但也会引入阵列导向矢量变换误差,影响 DOA 估计性能。稀疏阵列有多种形式,如 Liu 等^[13]使用的嵌套阵列、Zhou 等^[14]使用的互质阵、Moffet^[15]使用的最小冗余阵列等。Zhou 等^[14]使用 7 个阵元互质阵列扩展到 13 个阵元的均匀线阵,提高了 DOA 估计性能。Kim 等^[16]提出了一种基于变换矩阵的均匀圆阵列孔径扩展方法,通过对比扩展前后的信号协方差矩阵获取变换矩阵,提升了 DOA 分辨率。Liu 等^[17]分析了阵列协方差矩阵的结构,利用小孔径阵列协方差矩阵拟合大孔径阵列协方差矩阵,实现了阵元个数可控的阵列扩展,提升了 DOA 估计性能。上述阵列孔径扩展方法主要基于信号模型和阵列结构设计,在一定条件下能够有效扩展阵列孔径并提升 DOA 估计性能。然而,这些传统方法通常面临两大挑战:一是计算复杂度较高,例如需要求解复杂的协方差矩阵重构优化问题;二是对数据量的依赖性强,需要采集足够多的快拍信号来准确构建协方差矩阵。

将阵列孔径扩展视为从小孔径阵列信号到大孔径阵列信号的非线性映射,为解决上述挑战提供了新的思路。深度神经网络(deep neural network, DNN)以其强大的非线性拟合能力,成为实现这一映射的有力工具^[18]。近期研究^[19]探索了数据驱动的阵列孔径扩展方法,通过全连接网络(fully connected network, FCN)直接从单快拍原始信号生成扩展后的阵列信号。该方法摆脱了对多快拍信号统计量的依赖,显著降低了计算复杂度和对数据采集的要求,验证了深度学习在单快拍孔径扩展任务上的可行性。

然而,FCN 在处理信号时仅能提取全局特征,对于复杂信号中蕴含的多尺度信息捕捉能力有限。为了克服这一局限性并进一步提升扩展性能,本研究提出一种新型的阵列孔径扩展网络(aperture expansion network, AENet)。相较于现有方法,AENet 的关键区别在于:

1) 引入多尺度卷积模块:该设计能够并行提取信号在不同尺度下的局部和全局特征,增强了网络对复杂信号模式的感知和学习能力。

2) 引入通道注意力机制:通过该机制优化特征融合过程,AENet 能够自适应地为不同特征通道分配权重,使网络能够聚焦于对孔径扩展任务关键的特征信息,从而实现更高效的特征提取与利用。

仿真结果表明,与直接使用原始小孔径阵列进行 DOA 估计相比,经过 AENet 扩展后的阵列能够显著提升估计性能;与基于 FCN 的孔径扩展方法^[19]相比,AENet 具有多尺

度特征提取和利用能力,获得了更高的估计准确率;与传统数值方法^[17]相比,AENet 在获得更优估计性能的同时,大幅降低计算复杂度。

1 信号模型

考虑包含 M 个阵元的均匀线阵,阵元间距为 d 。阵列接收 K 个远场窄带目标信号,入射角分别为 $\theta_k, k = 1, 2, \dots, K$ 。单次快拍接收的信号 $\mathbf{x} \in \mathbb{C}^{M \times 1}$ 可以表示为:

$$\mathbf{x} = \sum_{k=1}^K s_k \mathbf{a}(\theta_k) + \mathbf{w} \quad (1)$$

其中, s_k 是当前快拍下第 k 个目标的信号, $\mathbf{x} \in \mathbb{C}^{M \times 1}$ 为加性高斯白噪声, $\mathbf{a}(\theta_k) \in \mathbb{C}^{M \times 1}$ 为阵列导向矢量,可以表示为:

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

式中: λ 为信号的波长。

阵列孔径扩展的目标是利用当前小孔径阵列(含 M 个阵元)的接收信号 $\mathbf{x} \in \mathbb{C}^{M \times 1}$ 构建出一个大孔径阵列(含 $\bar{M}$ 个阵元, $\bar{M} > M$)的接收信号 $\bar{\mathbf{x}} \in \mathbb{C}^{\bar{M} \times 1}$ 。大孔径阵列单次快拍接收的信号 $\bar{\mathbf{x}}$ 可以表示为:

$$\bar{\mathbf{x}} = \sum_{k=1}^K s_k \bar{\mathbf{a}}(\theta_k) + \bar{\mathbf{w}} \quad (3)$$

其中, $\bar{\mathbf{w}} \in \mathbb{C}^{\bar{M} \times 1}$ 为大孔径阵列的加性高斯白噪声, $\bar{\mathbf{a}}(\theta_k) \in \mathbb{C}^{\bar{M} \times 1}$ 为大孔径阵列导向矢量:

$$\bar{\mathbf{a}}(\theta_k) = [1, e^{-j\frac{2\pi}{\lambda}d\sin\theta_k}, \dots, e^{-j\frac{2\pi}{\lambda}(\bar{M}-1)d\sin\theta_k}]^T \quad (4)$$

由式(1)和(3)可以看出,小孔径与大孔径阵列的接收信号均依赖于 K 个目标的入射角,因此两种阵列的接收信号之间存在一定的关联关系。举例来说,假设大孔径阵列的规模是小孔径阵列的 2 倍(即 $\bar{M} = 2M$),且仅接收单目标源信号(即 $K = 1$),在忽略噪声的情况下,大孔径阵列的接收信号 $\bar{\mathbf{x}}$ 可以表示为:

$$\bar{\mathbf{x}} = \begin{bmatrix} \mathbf{x} \\ e^{j\frac{2\pi}{\lambda}Md\sin\theta_1} \cdot \mathbf{x} \end{bmatrix} \quad (5)$$

此时,大孔径阵列和小孔径阵列接收信号之间存在一种简单的线性映射关系。

然而,在接收多目标源信号的情况下,大、小孔径阵列接收信号之间的映射关系不再是简单的线性关系。为了便于表示,定义 $\mathbf{x}_k = s_k \bar{\mathbf{a}}(\theta_k)$,则在忽略噪声的情况下,式(1)给出的小孔径阵列的接收信号可以表示为 $\mathbf{x} = \sum_{k=1}^K \mathbf{x}_k$ 。进一步,大孔径阵列的接收信号 $\bar{\mathbf{x}}$ 可以表示为:

$$\bar{\mathbf{x}} = \begin{bmatrix} \mathbf{x} \\ \sum_{k=1}^K e^{j\frac{2\pi}{\lambda}Md\sin\theta_k} \cdot \mathbf{x}_k \end{bmatrix} \quad (6)$$

可见,此时大、小孔径阵列接收信号之间的关系受到目标入射角、阵列孔径等多种因素的共同影响,表现为复杂的

非线性映射,为阵列孔径扩展带来了挑战。

2 基于深度学习的阵列孔径扩展方法

2.1 神经网络设计

本节提出一种基于深度学习的阵列孔径扩展神经网络 AENet,建立从小孔径阵列接收信号到大孔径阵列接收信号的映射模型。具体而言,利用神经网络对小孔径阵列接收信号进行特征提取、融合与高维扩展,实现大孔径阵列接收信号的重构。AENet 的网络结构如图 1 所示,主要包括输入层、特征提取模块、通道注意力模块、特征扩展模块和输出层。




图 1 AENet 网络结构

Fig. 1 AENet network structure

网络输入为小孔径阵列接收信号,该信号为复数形式,其实部和虚部分别作为独立的两个通道输入网络;网络输出为大孔径阵列接收信号,同样分为实部和虚部两个通道。

特征提取模块用于从输入信号中提取有效的特征信息。不同于现有基于全连接网络的全局特征提取方法^[19],本文采用多尺度卷积神经网络结构,以更好地捕获小孔径阵列接收信号中的多层次特征。如图 1 中左下子图所示,多尺度卷积模块中较大的卷积核用于提取小孔径阵列接收信号的全局低频特征,而较小的卷积核则可提取信号的局部高频特征。这种多尺度设计能增强模块对复杂信号的特征表达能力。

直接将特征提取模块获取的多尺度特征信息用于信号扩展映射,往往扩展效果不佳。为此,本研究引入了通道注意力模块,用于有效融合提取的局部和全局特征。如图 1 中右下子图所示,该模块针对每个输入特征学习得到对应的权重,然后将生成的权重与输入特征相乘,实现对关键特征的自适应选择。在网络训练过程中,该模块会赋予对信号扩展贡献较大的特征更高的权重,同时抑制非关键特征对结果的影响。通过这种机制,该模块能够增强高权重特征的主导作用,从而提升扩展信号的质量。

特征扩展模块用于完成小孔径阵列接收信号向大孔径阵列接收信号的特征映射。本研究采用一种类似自编码器

的结构,通过特征扩展与压缩完成映射过程。在编码阶段,隐藏层维度逐渐增大,通过扩大特征空间的容量,增强对原始特征的表征能力;在解码阶段,对扩展后的高维特征进行压缩和映射,最终生成与大孔径阵列接收信号维度一致的输出。

2.2 网络训练方法

网络训练采用监督学习方法,以单快拍小孔径阵列接收信号作为输入特征,大孔径阵列接收信号作为训练标签。为了提升模型泛化能力,训练样本涵盖了多角度、多信噪比等实际应用中特征变化较大的多种场景。具体而言,训练集考虑两个目标信号,其入射角在 $[-60^\circ, 60^\circ]$ 随机均匀分布,信噪比随机分布于 $[0 \text{ dB}, 30 \text{ dB}]$ 。给定随机产生的入射角和信噪比,分别采样得到包含 10 和 20 个阵元的小孔径、大孔径阵列接收信号,共生成 500 000 个样本,其中 90%用于网络训练,10%用于验证。

训练损失函数采用均方误差,即扩展的大孔径阵列接收信号与真实信号之间的误差。优化算法使用 Adam 优化器,初始学习率为 0.001,每 10 个训练周期学习率减半,最大训练周期为 100,批大小设为 128。

通过对网络超参数的调试,本文观察到激活函数的选择对模型学习性能影响较为显著。作为激活函数选择的依据,本文采用扩展的大孔径阵列接收信号进行 DOA 估计,并以 DOA 估计的准确率作为评估指标。当角度估计误差 $<1^\circ$ 时认为估计正确。评估中采用两种经典的 DOA 估计算法,分别为常规波束形成(conventional beamforming, CBF)算法和正交匹配追踪(orthogonal matching pursuit, OMP)算法。相比之下,OMP 算法具有更优的性能,但计算复杂度也较高。

如图 2 所示,对 4 种常用激活函数(Tanh、ReLU、LeakyReLU 和 ELU)在 CBF 和 OMP 算法下的估计性能进行了对比。可以看出,对于两种 DOA 估计算法,Tanh 函数对应的估计性能最差,ELU 函数虽然稍优于 Tanh,但与其他激活函数相比仍存在较大差距。ReLU 函数和 LeakyReLU 函数对应的估计性能较好,且非常接近。考虑到 LeakyReLU 的计算复杂度高于 ReLU,最终选择 ReLU 作为模型的激活函数。

3 仿真结果

本节对提出的 AENet 网络进行性能评估,验证其阵列孔径扩展效果,以及基于扩展后的阵列信号进行 DOA 估计的性能。AENet 能够利用小孔径阵列的单个快拍信号实现孔径扩展。在此条件下,传统基于阵列信号协方差矩阵或高阶累积量的扩展孔径方法由于统计量估计误差较大而往往表现不佳。因此,仿真中主要选取文献[19]提出的基于 FCN 的阵列孔径扩展方法作为对比基准。FCN 方法将角度空间划分为若干区间,然后针对每个角度区间分别训练模型来实现孔径扩展。这种方法在实际应用中存在两




图 2 不同激活函数对 DOA 估计性能的影响

Fig. 2 Impact of different activation functions on the performance of DOA estimation

方面的局限:一是在训练阶段需要针对多个角度区间分别训练模型,计算复杂度较高;二是在推断阶段需要提前获知目标所在的角度区间,以选择对应的模型。与之相比, AENet 仅需针对整个角度空间训练单一模型,显著简化了模型训练和推断,有效克服了上述问题。仿真参数与第 2.2 节训练样本生成时的参数设置一致。

3.1 AENet 的阵列孔径扩展结果

首先,比较 AENet 学习得到的大孔径阵列接收信号与真实大孔径阵列接收信号之间的关系。仿真中随机设置两个目标的入射角度分别为 -40.6° 和 -32.6° (间隔 8°),信噪比设为 30 dB,得到的原始小孔径阵列接收信号、AENet 扩展的大孔径阵列接收信号,以及真实大孔径阵列接收信号的实部数据如图 3 所示,其中横轴表示阵元编号。从图 3 中可以观察到,AENet 输出的前 10 个阵元的信号与原始小孔径阵列信号比较接近,而后 10 个阵元信号实现了阵列孔径的扩展,生成的信号与真实大孔径信号具有相似的变化趋势。




图 3 大、小孔径阵列和 AENet 扩展后阵列接收信号的实部

Fig. 3 Real parts of the received signals for large-aperture, small-aperture, and AENet-based expanded-aperture arrays

为了评估扩展后的大孔径阵列接收信号对 DOA 估计性能的提升作用,比较了 AENet 学习的大孔径阵列接收信号、原始小孔径阵列接收信号,以及真实大孔径阵列接收信号在经过 CBF 算法处理后的角度谱,结果如图 4 所示。从图 4 中可以看出,小孔径阵列的角度分辨率较低,仅在角度谱中生成一个单一峰值,位于两个真实目标之间,无法有效地区分两个目标。大孔径阵列能够生成更高分辨率的角度谱,成功区分两个目标。AENet 扩展的大孔径阵列接收信号表现出接近真实大孔径阵列的分辨能力,角度谱中同样观察到两个明显的峰值,成功区分两个目标的角度。




图 4 3 种阵列的角度谱

Fig. 4 Angular spectrum of three kinds of array

3.2 与传统数值方法的性能和复杂度比较

在不同信噪比下,对 3 种孔径扩展方法的 DOA 估计性能对比,结果如图 5 所示,包括传统的基于协方差矩阵的方法^[17]和两种基于深度学习的方法(AENet 和 FCN)。仿真中,两目标的角度间隔固定为 8° ,角度随机分布在 $[-60^\circ, 60^\circ]$,DOA 估计采用 OMP 算法。从图 5 中可知,3 种孔径扩展方法均优于直接使用小孔径阵列的估计结果。其中,相比于传统数值扩展方法,两种学习方法能够获得更好的估计性能。

在信噪比为 20 dB 时,比较 3 种孔径扩展方法的平均推理时长,结果如表 1 所示。传统数值方法由于需要采用复杂的迭代算法求解协方差矩阵重构优化问题^[17],其推理时长远高于两种深度学习方法。

表 1 不同扩展算法的平均推理时长

Table 1 Average inference time of different expansion methods

扩展方法	数值算法	FCN	AENet
推理时长/ms	677.9	2.43	3.14

考虑到传统数值方法计算复杂高且性能低于学习方法,后续的仿真将主要集中在 AENet 和 FCN 两种基于深度学习的扩展方法之间的比较。

3.3 不同信噪比下的孔径扩展性能

在不同信噪比条件下,对比原始小孔径阵列、真实大孔




图 5 学习方法与传统数值方法的 DOA 估计准确率比较

Fig. 5 Comparison of accurate rate of DOA estimation by learning and traditional numerical methods

径阵列,以及扩展得到的大孔径阵列的 DOA 估计性能,结果如图 6 所示。仿真中,两目标的角度间隔固定为 8° ,角度随机分布在 $[-60^\circ, 60^\circ]$ 。从图 6 中可以看出,对于小孔径阵列,CBF 算法在所有信噪比条件下的正确率均低于 5%,无法有效区分两个目标。相较而言,OMP 算法性能有所提升,在信噪比为 30 dB 时,正确率接近 40%。然而,真实的大孔径阵列在信噪比较低时即可展现明显优势(如在信噪比为 0 dB 时,CBF 算法正确率已达 40%),高信噪比下正确率进一步提升,其中使用 OMP 算法时,在信噪比为 20 dB 时的正确率已接近 100%。




图 6 不同信噪比下的 DOA 估计准确率

Fig. 6 Accurate rate of DOA estimation under different signal to noise ratio

通过 AENet 对小孔径阵列进行孔径扩展后,CBF 算法在信噪比为 30 dB 时的正确率提升至 45%,显著优于原始小孔径阵列信号。在同样条件下,OMP 算法的估计准确率增长至约 85%。值得注意的是,基于 AENet 扩展后的阵列信号,即便使用计算复杂度较低的 CBF 算法,其性能已优于原始小孔径阵列信号使用 OMP 算法的估计效果。这表明,结合孔径扩展方法和低复杂度的 DOA 估计算法,可以在保证较高估计性能的同时显著降低计算复杂度。

此外,与 FCN 模型相比,AENet 在所有信噪比条件下均表现出更优的 DOA 估计性能。例如,在信噪比为 30 dB 时,AENet 在 CBF 和 OMP 算法的估计准确率均获得了约 7% 的准确率提升。

3.4 不同入射角度下的孔径扩展性能

阵列的角度分辨率与目标入射角度有关。当目标入射角度接近 0° 时,阵列的角度分辨率通常最高;而当目标入射角度接近角度区间的边缘时,分辨率有所下降。为了评估 AENet 在不同入射角度下的孔径扩展性能,仿真中随机选取两组目标角度进行性能对比。第 1 组目标角度固定为 2.2° 和 10.2° (接近中心角度 0°),第 2 组目标角度固定为 50.2° 和 58.2° (接近角度区间的边缘),仿真结果如图 7 和 8 所示。从图 7 中可以看出,当目标的入射角接近中心角度时,扩展阵列的 DOA 估计性能显著优于小孔径阵列。例如,在信噪比为 30 dB 时,基于扩展阵列信号的 CBF 算法的估计正确率达到 62%,OMP 算法的估计正确率则超过 89%。当目标角度接近区间边缘时,如图 8 所示,CBF 算法在不同的阵列下均表现不佳。当采用 OMP 算法时,基于扩展阵列信号的 DOA 估计正确率达到 75%,显著优于原始小孔径阵列的 20%。相比之下,FCN 模型性能在两种算法下均低于 AENet。




图 7 第 1 组入射角下的估计准确率

Fig. 7 Accurate rate of DOA estimation for the first set of incident angles

3.5 不同入射角间隔下的孔径扩展性能

目标角度间隔是影响阵列分辨能力的关键因素。为了研究其对阵列扩展的性能影响,仿真中设置第 1 个目标的角度固定为 3° ,两个目标的角度间隔分别设为 $1^\circ \sim 14^\circ$,信噪比设为 20 dB。

仿真结果如图 9 和 10 所示。仿真结果表明,使用 CBF 算法,当角度间隔 $< 3^\circ$ 时,无论是小孔径阵列还是大孔径阵列,均无法准确分辨两个目标。当角度间隔增大至 14° 时,小孔径阵列的正确率提升至 65%,大孔径阵列的正确率达到 98%。基于 AENet 扩展阵列的估计正确率接近大孔径阵列,达到 95%,FCN 模型对应的正确率为 90%。使用 OMP 算法时,当角度间隔为 10° 时,大孔径阵列和小孔径阵




图8 第2组入射角下的估计准确率

Fig. 8 Accurate rate of DOA estimation for the second set of incident angles

列的DOA估计正确率分别为98%和85%,AENet扩展阵列的估计正确率为89%,FCN扩展阵列的估计正确率为85%。




图9 CBF算法在不同角度间隔下的估计准确率

Fig. 9 Accurate rate of DOA estimation of the CBF algorithm for various angular separations




图10 OMP算法在不同角度间隔下的估计准确率

Fig. 10 Accurate rate of DOA estimation of the OMP algorithm for various angular separations

4 结 论

本研究提出了一种基于多特征融合的阵列孔径扩展学习方法,利用小孔径阵列的单快拍信号来生成大孔径阵列信号。所设计的深度神经网络AENet采用多尺度卷积模块来提取不同尺度的信号特征,提升了特征提取能力,同时引入通道注意力机制对不同通道的特征进行加权融合,增强了模型对关键特征利用效果。仿真结果表明,在不同的信噪比、入射角度、角度间隔条件下,所提出方法的孔径扩展效果优于现有的基于深度学习的孔径扩展方法,并且扩展后的阵列信号显著提高了DOA估计性能,与原始小孔径阵列相比展现出更优的角度分辨能力;同时,与传统数值孔径扩展方法相比,所提出方法能够大幅降低计算耗时,提高孔径扩展实时性。

参考文献

- [1] 李铭,侯艳丽,苏佳. OFDM系统中一种低复杂度的TOA和DOA联合估计算法[J]. 电子测量技术,2023,46(10):155-163.
LI M, HOU Y L, SU J. A low-complexity joint TOA and DOA estimation in OFDM system[J]. Electronic Measurement Technology, 2023,46(10):155-163.
- [2] 周英钢,邵佳伟. 对数螺旋阵列的相干信号DOA估计研究[J]. 电子测量与仪器学报,2023,37(2):220-227.
ZHOU Y G, SHAO J W. Research on DOA estimation of coherent signals from logarithmic spiral arrays[J]. Journal of Electronic Measurement and Instrumentation, 2023,37(2):220-227.
- [3] 陈果,卢永刚. 宽带声源方位估计的多频稀疏贝叶斯学习改进算法[J]. 仪器仪表学报,2023,44(5):302-312.
CHEN G, LU Y G. Improved multi-frequency sparse Bayesian learning method for DOA estimation of the wideband sound source [J]. Chinese Journal of Scientific Instrument, 2023,44(5):302-312.
- [4] LIN J CH, MA X CH, YAN SH F, et al. Time-frequency multi-invariance ESPRIT for DOA estimation [J]. IEEE Antennas and Wireless Propagation Letters, 2015, 15: 770-773.
- [5] FISHLER E, HAIMOVICH A, BLUM R S, et al. Spatial diversity in radars—Models and detection performance [J]. IEEE Transactions on signal processing, 2006, 54(3): 823-838.
- [6] 牟仕林. 非均匀稀疏阵DOA估计研究[D]. 成都: 电子科技大学,2020.
MOU SH L. Research on DOA estimation of non-uniform sparse arrays [D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [7] BILIK I, VILLEVAL S, BRODESKI D, et al.

- Automotive multi-mode cascaded radar data processing embedded system[C]. 2018 IEEE Radar Conference (RadarConf18), 2018: 0372-0376.
- [8] DOGAN M C, MENDEL J M. Applications of cumulants to array processing. I. aperture extension and array calibration[J]. IEEE Transactions on Signal Processing, 1995, 43(5): 1200-1216.
- [9] CHEVALIER P, FERREOL A. On the virtual array concept for the fourth-order direction finding problem[J]. IEEE Transactions on Signal Processing, 1999, 47(9): 2592-2595.
- [10] FRIEDLANDER B, WEISS A J. Direction finding using spatial smoothing with interpolated arrays[J]. IEEE Transactions on Aerospace and Electronic Systems, 1992, 28(2): 574-587.
- [11] CUI AO, XU T, YU W CH, et al. An array interpolation based compressive sensing DOA method for sparse array[C]. 2019 3rd International Conference on Imaging, Signal Processing and Communication (ICISPC), 2019: 24-27.
- [12] HYBERG P, JANSOON M, OTTERSTEN B. Array interpolation and bias reduction[J]. IEEE Transactions on Signal Processing, 2004, 52(10): 2711-2720.
- [13] LIU CH L, VAIDYANATHAN P P. Super nested arrays: Linear sparse arrays with reduced mutual coupling—Part I: Fundamentals[J]. IEEE Transactions on Signal Processing, 2016, 64(15): 3997-4012.
- [14] ZHOU CH W, GU Y J, FAN X, et al. Direction-of-arrival estimation for coprime array via virtual array interpolation [J]. IEEE Transactions on Signal Processing, 2018, 66(22): 5956-5971.
- [15] MOFFET A. Minimum-redundancy linear arrays[J]. IEEE Transactions on antennas and propagation, 1968, 16(2): 172-175.
- [16] KIM Y S, KIM Y S, KANG H R, et al. A new covariance matrix estimation method for resolution enhancement via virtual expansion[C]. WCC 2000-ICSP 2000. 5th International Conference on Signal Processing Proceedings, 2000, 1: 189-192.
- [17] LIU K X, FU J, ZOU N, et al. Array aperture extension method using covariance matrix fitting[J]. Acta Acustica, 2023, 48(5): 911-919.
- [18] 包广斌, 罗瞳, 彭璐, 等. 3DuA-Net: 融合 3D 卷积和注意力的雷达回波外推预报[J]. 电子测量技术, 2024, 47(15): 153-160.
- BAO G B, LUO T, PENG L, et al. 3DuA-Net: Fusion of 3D convolution and attention for radar echo extrapolation forecasting[J]. Electronic Measurement Technology, 2024, 47(15): 153-160.
- [19] AHMED A M, THANTRIGE U S K P M, GAMAL A E, et al. Deep learning for DOA estimation in MIMO radar systems via emulation of large antenna arrays [J]. IEEE Communications Letters, 2021, 25(5): 1559-1563.

作者简介

张玉涛, 硕士, 工程师, 主要研究方向为雷达信号处理。

E-mail: zhangyutao566@163.com

张志武, 硕士, 工程师, 主要研究方向为雷达信号处理。

E-mail: 543585817@qq.com

韩天水, 硕士研究生, 主要研究方向为雷达信号处理。

E-mail: tianshuihan@buaa.edu.cn

郭思远, 硕士研究生, 主要研究方向为雷达信号处理。

E-mail: zy2402205@buaa.edu.cn

韩圣千(通信作者), 博士, 副教授, 主要研究方向为通信和雷达信号处理。

E-mail: sqhan@buaa.edu.cn

孙进平, 博士, 教授, 主要研究方向为雷达信号处理。

E-mail: sunjinping@buaa.edu.cn