

# 基于深度学习的阵列天线自适应波束形成研究综述

许 峰<sup>1,2</sup>, 潘子豪<sup>1</sup>, 王 宁<sup>1</sup>, 郭道省<sup>1</sup>

(1. 中国人民解放军陆军工程大学通信工程学院,南京 210001;2. 南京熊猫汉达科技有限公司,南京 210001)

**摘要:** 随着阵列天线规模不断增加、抗干扰场景日益复杂,传统的自适应波束形成方法往往计算量大,深度学习凭借其强大的数据驱动能力,为突破传统自适应波束形成的性能瓶颈提供了新思路。本文系统综述了深度学习在阵列天线波束形成领域的研究现状和发展趋势。首先,回顾了从 Howells-Applebaum 自适应处理器到基于凸优化的鲁棒波束形成等传统波束形成算法的发展历程。其次,详细分析了卷积神经网络(Convolutional neural network, CNN)、循环神经网络(Recurrent neural network, RNN)、长短期记忆(Long short-term memory, LSTM)网络等深度学习模型在波束形成中的创新应用。研究表明,深度学习方法凭借其强大的非线性建模能力、端到端优化特性和环境适应性,在提升系统性能方面具有显著优势。特别地,在移动通信领域,基于深度学习的波束形成方法显著提升了大规模多输入多输出(Multiple input multiple output, MIMO)系统的计算效率和环境适应能力。在雷达信号处理中,深度学习模型有效增强了抗干扰性能和目标检测精度。在声学信号处理方面,深度神经网络实现了更精确的声源定位和噪声抑制。最后,本文探讨了网络架构创新、实时处理优化、鲁棒性增强、跨场景迁移学习、理论基础深化和新型应用拓展等未来研究方向。

**关键词:** 波束形成;深度学习;神经网络;阵列信号处理

中图分类号: TN911.7;TP183 文献标志码:A

## Review on Deep Learning-Based Adaptive Beamforming for Array Antennas

XU Zheng<sup>1,2</sup>, PAN Zihao<sup>1</sup>, WANG Ning<sup>1</sup>, GUO Daoxing<sup>1</sup>

(1. College of Communications Engineering, Army Engineering University of PLA, Nanjing 210001, China;2. Nanjing Panda Handa Technology Co., Ltd., Nanjing 210001, China)

**Abstract:** With the increasing of array antennas and the growing complexity of anti-jamming, traditional adaptive beamforming methods often suffer from high computational complexity. Deep learning, with its powerful data-driven capabilities, offers a novel approach to overcoming the performance bottlenecks of traditional adaptive beamforming. This paper provides a systematic review on current studies and development trends of deep learning in array antenna beamforming. First, we revisit the evolution of traditional beamforming algorithms, ranging from the Howells-Applebaum adaptive processor to robust beamforming based on convex optimization. Second, we analyze the innovative applications of deep learning models such as convolutional neural networks (CNNs), recurrent neural networks (RNNs), and long short-term memory (LSTM) networks in beamforming. This review demonstrates that deep learning

methods exhibit significant advantages in improving system performance due to their powerful nonlinear modeling capabilities, end-to-end optimization characteristics, and environmental adaptability. Specifically, in mobile communications, deep learning-based beamforming methods substantially enhance the computational efficiency and environmental adaptability of massive multiple input multiple output (MIMO) systems. In radar signal processing, deep learning models effectively improve anti-jamming performance and target detection accuracy. In acoustic signal processing, deep neural networks enable more precise sound source localization and noise suppression. Finally, this paper explores future research directions, including network architecture innovation, real-time processing optimization, robustness enhancement, cross-scenario transfer learning, theoretical foundation deepening, and novel application expansion.

**Key words:** beamforming; deep learning; neural networks; array signal processing

## 引 言

随着无线通信、雷达探测和声学成像等技术的快速发展,对空间信号的高效操控与处理需求日益迫切。波束形成作为阵列信号处理的核心技术之一,通过协调多个天线或传感器单元的辐射特性,实现了信号在空间维度上的选择性增强与干扰抑制,成为提升系统性能的关键手段<sup>[1-2]</sup>。传统单天线系统受限于固定的辐射方向性与有限的自由度,难以应对复杂电磁环境下的多径干扰、噪声叠加以及动态目标跟踪等挑战。阵列天线的出现为解决这些问题提供了新的可能性:通过将多个天线单元按特定规则排列,并结合波束形成算法,系统能够在空域中灵活调控波束的指向、形状与增益。例如,在5G通信中,大规模多输入多输出(Multiple input multiple output, MIMO)技术依赖波束形成实现多用户空分复用,显著提升网络容量<sup>[3-4]</sup>;在相控阵雷达中,电子扫描波束取代机械转动,极大提高了目标搜索与跟踪效率<sup>[5]</sup>。自适应波束形成技术的发展历程可追溯至20世纪60年代,图1展示了波束形成的发展脉络。1965年Howells<sup>[6]</sup>提出自适应陷波的旁瓣对消器开创了自适应波束形成的先河。1967年Widrow & Mantey提出的最小均方(Least mean squares, LMS)算法<sup>[7]</sup>奠定了早期自适应优化的基础。1969年Capon<sup>[8]</sup>提出的最小方差无畸变响应(Minimum variance distortionless response, MVDR)算法至今仍是该领域的核心方法。1972年Frost<sup>[9]</sup>提出的线性约束最小方差(Linearly constrained minimum variance, LCMV)算法和1974年Reed等<sup>[10]</sup>提出的样本矩阵求逆(Sample matrix inversion, SMI)算法进一步推动了实时系统的应用发展。为提升系统鲁棒性,研究人员在20世纪80~90年代提出了多种改进方法。其中,Hung等<sup>[11]</sup>的特征子空间方法、Carlson<sup>[12]</sup>的对角加载技术和Compton<sup>[13]</sup>的功率倒置算法分别从不同角度增强了系统性能。进入21世纪后,Bell等<sup>[14]</sup>提出的贝叶斯估计方法、Li等<sup>[15]</sup>提出最坏情况优化方法、Gu等<sup>[16]</sup>提出协方差矩阵重构的波束形成技术,进一步完善了鲁棒波束形成理论。为考虑信号频率对波束形成的影响,1972年Forst<sup>[9]</sup>采用LCMV的思想提出了基于有限冲激响应(Finite impulse response, FIR)滤波器的宽带空时波束形成方法。为提升宽带波束形成器的鲁棒性,Gooch等<sup>[17]</sup>和Duan等<sup>[18]</sup>将FIR滤波器替换为无限冲激响应(Infinit impulse response, IIR)滤波器。Seydnejad等<sup>[19]</sup>改进IIR滤波器得到Laguerre宽带波束形成器。Buckley等<sup>[20]</sup>将子带和空域滤波结合,启发了基于离散傅里叶变换(Discrete Fourier transform, DFT)的宽带空时波束形成。

然而,传统算法在面对高维数据处理、非线性场景建模和实时计算需求等方面仍存在局限性。传统算法处理高维数据时的局限性尤为明显:随着阵列阵元数量增加,数据维度同步攀升,传统波束形成算法如MVDR算法等,其协方差矩阵估计的精度会因样本数量不足而显著下滑,导致波束主瓣展宽等

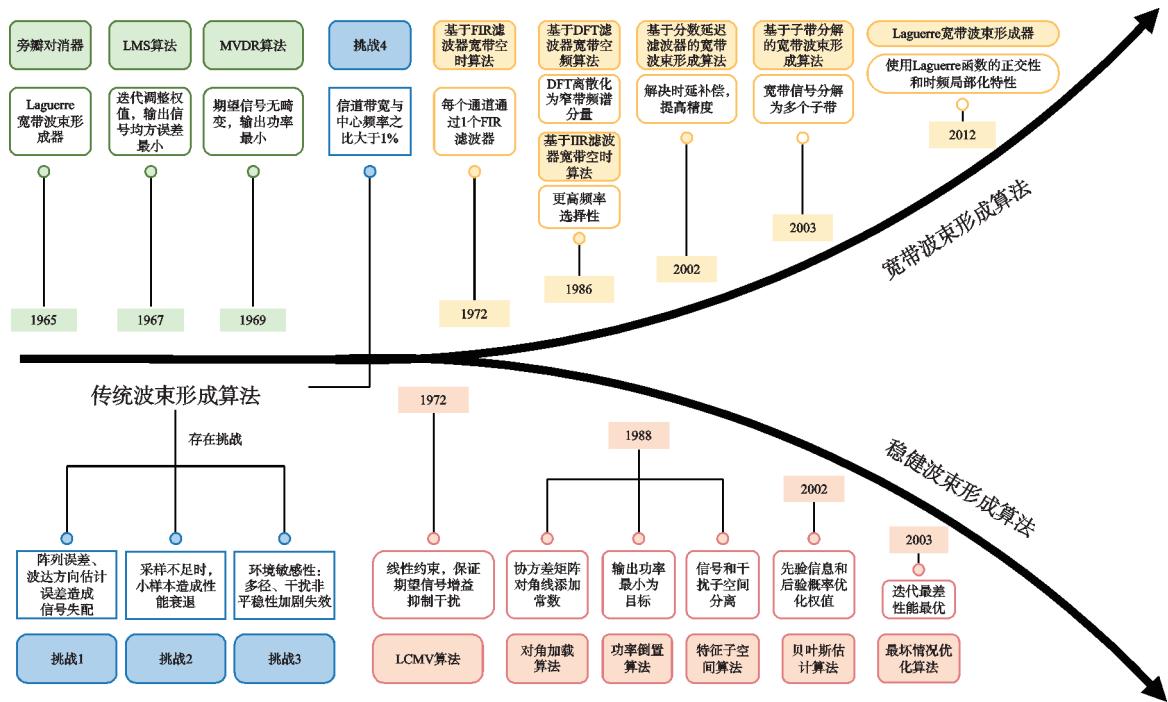


图1 波束形成算法发展脉络  
Fig.1 Lineage of beamforming algorithms

问题。面对非线性场景,传统算法难以应对复杂的多径效应、非平稳干扰等强非线性因素,例如在存在严重码间干扰的通信场景中,基于线性滤波的传统方法无法准确建模信号传播的非线性畸变,导致目标信号提取精度大幅降低;而在实时计算需求上,传统算法往往需要复杂的矩阵运算和迭代优化过程,当阵列规模较大或信号环境动态变化时,其计算耗时显著增加,无法满足雷达、通信等领域对实时波束赋形的要求,极大限制了在动态复杂场景中的应用效能。近年来,深度学习技术的快速发展为解决这些挑战提供了新的思路。与传统方法相比,深度学习方法在波束形成领域展现出3个方面的显著优势。(1)强大的非线性建模能力。Wu等<sup>[21]</sup>的卷积神经网络(Convolutional neural network, CNN)架构能够直接学习空间特征,避免复杂的协方差矩阵估计。Mallioras等<sup>[22]</sup>的门控循环单元(Gated recurrent unit, GRU)网络通过纳入非各向同性辐射和互耦效应,实现非线性误差的自适应补偿。Xue等<sup>[23]</sup>的宽带权重生成网络克服了传统方法在宽带条件下的性能退化。(2)端到端优化特性。Liu等<sup>[24]</sup>的互质传感器阵列权重向量估计注意力卷积神经网络(Coprime sensor array weight vector estimation-attention convolutional neural network, CAWE-ACNN)算法避免了复杂的中间处理步骤。Liao等<sup>[25]</sup>的两阶段CNN实现了从信号到权重的完整优化路径。Took等<sup>[26]</sup>的权重共享机制显著提升了算法收敛性能。(3)优异的环境适应性。Kassir等<sup>[27]</sup>验证了多种网络架构的场景适应能力。Lin等<sup>[28]</sup>的方法有效处理了大规模阵列的复杂约束。Banu等<sup>[29]</sup>成功将深度学习扩展到MIMO复杂环境。这些技术优势使得深度学习在提升波束形成性能方面展现出巨大潜力。

尽管已有一些文献对神经网络在波束形成中的应用进行了综述,如Du等<sup>[30]</sup>的早期探索和Rawat等<sup>[31]</sup>的传统神经网络应用分析,但这些研究未能涵盖深度学习时代的进展。最近,Naji等<sup>[32]</sup>和Mosteghanemi等<sup>[33]</sup>的综述虽然关注了深度学习在波束形成中的应用,但在技术深度和系统性能方面仍有提升空间。

本文旨在系统梳理2016年以来基于深度学习的波束形成技术发展,重点关注CNN、循环神经网络(Recurrent neural network, RNN)、长短期记忆(Long short-term memory, LSTM)网络、径向基函数神经网络(Radial basis function neural network, RBFNN)、前馈神经网络(Feedforward neural network, FFNN)等深度神经网络在移动通信、雷达信号处理及声学信号处理等领域的创新应用。

## 1 研究方法

### 1.1 文献检索与筛选方法

#### 1.1.1 检索数据库

本研究选取了具有国际影响力的多个学术数据库作为文献来源。在专业工程领域,主要依托IEEE Xplore和IET Digital Library两大数据库,它们分别收录了电子、通信和电气工程等领域的核心期刊与重要会议论文。在综合科技文献方面,选择了Elsevier旗下的ScienceDirect、Springer出版社的SpringerLink以及开放获取平台MDPI,这些数据库涵盖了工程技术等多个学科领域的高质量研究成果。同时,为了及时掌握最新研究动态,本研究还纳入了预印本平台arXiv和学术搜索引擎Google Scholar,通过多库联合检索确保文献覆盖的完整性与时效性。

#### 1.1.2 检索策略设计

本研究采用多层次的检索策略,通过关键词的科学组合确保检索结果的精确性与全面性。核心关键词包括波束形成相关术语“beamforming”和“array antenna”,深度学习相关术语“deep neural network (DNN)”“neural network (NN)”,以及应用场景相关词汇“adaptive”“smart antenna”“phased array”等。在具体检索过程中,采用布尔逻辑运算符构建基础检索式和扩展检索式,通过精确匹配与模糊匹配相结合的方式,确保检索结果的查全率和查准率。检索过程中根据初步结果动态调整检索策略,不断优化关键词组合,以获取最相关的研究文献。

#### 1.1.3 时间范围确定

选择2016年作为文献检索的起始时间点具有重要的技术背景和现实意义。这一时期是深度学习从理论研究向工程应用转变的关键节点,图形处理单元(Graphics processing unit, GPU)和张量处理单元(Tensor processing unit, TPU)等深度学习专用硬件加速设备开始普及,TensorFlow、PyTorch等深度学习框架日趋成熟,计算资源门槛显著降低。这些技术条件的改善使得深度学习在波束形成领域的应用从概念验证阶段迈向实际部署阶段,研究范式发生根本性转变,应用场景不断拓展与深化。因此,以2016年为起点的文献检索能够全面把握深度学习在波束形成领域应用的关键发展历程。

#### 1.1.4 文献筛选标准

为确保所选文献的学术价值与参考意义,本研究建立了多维度的文献筛选标准。在质量评估方面,重点考察发表期刊的影响因子、会议的学术等级、论文的被引频次以及作者与机构的学术声誉。在内容相关性评估方面,着重分析论文的技术创新点、实验验证的完整性以及研究成果的应用价值与推广潜力。优先选择被引频次高、提供完整解决方案且实验验证充分的研究工作,确保入选文献能够代表该领域的研究前沿与发展趋势。

#### 1.1.5 文献管理方法

为系统化梳理和分析所获文献,本研究采用多层次的文献管理方法。首先按照研究方向、技术路线和应用场景对文献进行分类整理,建立结构化的文献数据库。其次,从每篇文献中提取关键技术创新点、实验方法与结果、研究局限性与未来展望等重要信息,形成详细的文献分析记录。通过这种系统化的文献管理方法,不仅确保了文献分析的全面性和深入性,也为后续的综述写作提供了可靠的资料支撑。

通过上述系统化的文献检索与筛选策略,本研究在广泛收集文献的基础上,重点聚焦深度神经网络在阵列天线自适应波束形成中的创新应用,为深入分析这一领域的研究现状与发展趋势奠定了坚实的文献基础。

## 1.2 文献搜索概述

基于前述检索策略,本研究对2016年至今深度神经网络在阵列天线波束形成领域的文献发表情况进行了系统分析。尽管波束形成技术的应用领域广泛,涉及声学、光学和电磁波等多个方向,但本研究重点关注其在阵列天线系统中的应用,特别是基于深度神经网络实现的智能波束形成方法。通过对文献发表数量的统计分析发现,该研究方向呈现出明显的阶段性特征。在2016~2021年期间,相关研究处于稳步发展阶段,年均发文量维持在3篇左右,主要集中在验证深度学习方法在波束形成中的可行性。这一时期的研究工作主要发表在《IEEE Transactions on Antennas and Propagation》《IEEE Access》等专业期刊上,研究内容以算法验证和性能对比为主。

2022年以来,随着ChatGPT引发新一轮人工智能研究热潮,深度学习在波束形成领域的应用研究显著活跃。年均发文量增长至5篇以上,且发表载体的学术水平明显提升,更多研究成果开始出现在《IEEE Transactions on Neural Networks and Learning Systems》《IEEE Transactions on Signal Processing》等高影响因子期刊上。研究内容也从早期的方法验证转向了复杂场景应用、理论创新和工程实现等更深层次的探索。

文献数量和质量的双重提升反映出深度神经网络在阵列天线波束形成领域已成为一个备受关注的研究热点。这种趋势一方面源于深度学习技术本身的发展,另一方面也体现了智能波束形成在5G/6G通信、相控阵雷达等现代通信与探测系统中的重要应用价值。通过对文献发展态势的分析,可以预见该领域在未来几年仍将保持较高的研究热度,并可能在算法创新、理论突破和工程应用等方面产生更多重要成果。

## 2 波束形成基础

### 2.1 模型建立前提及假设

为确保波束形成系统模型数据可处理性,从信号特征、阵列结构和传播环境3个维度阐述基本假设,以合理简化实际工程应用。

(1)信号特性。假设阵列天线所有待处理信道的带宽远小于载波频率,即阵列天线接收的信号均为窄带信号,这一假设将阵列天线阵元接收的时延效应简化为阵元间的相位差;同时,假设信号源到阵列天线的距离远大于阵列孔径,入射信号可近似为平面波且信号的幅度衰减在阵列范围内基本一致。

(2)阵列结构。假设阵元天线所有阵元具有相同的全向辐射方向图,建模时暂不考虑阵元间互耦效应,阵元增益在工作频带内保持恒定,且阵列天线的阵元排列具有规则性,阵元间距通常为半波长。

(3)传播环境。为简化数学模型,往往假设信道为线性时不变,多径效应多被忽略或建模为有限数量的离散路径,同时大气衰减和散射效应被忽略。

上述假设构成了波束形成系统建模的理论基础。需要注意的是,这些假设虽然在大多数应用场景下是合理的,但在特定情况下可能需要放宽或修改。例如在近场应用中,需要考虑球面波效应;在宽带系统中,需要引入频率选择性处理;在密集阵列中,需要考虑互耦效应;在高动态场景中,需要考虑多普勒效应。

因此,在实际系统设计中,需要根据具体应用场景和性能要求,合理选择和调整这些假设,以在模型复杂度和精确度之间取得平衡。同时,随着硬件技术和算法理论的发展,某些传统假设可能被突破,

产生新的理论框架和处理方法。这也是波束形成技术持续发展的动力之一。

## 2.2 阵列天线模型建立

阵列天线系统的数学建模是波束形成研究的基础。本节以均匀线性阵列(Uniform linear array, ULA)为例,系统阐述阵列天线的数学模型,作为后续的波束形成算法的模型基础。

构建一个线性阵列,由 $M$ 个相同阵元构成,阵元线性均匀分布,阵元间距为 $d$ ,通常 $d=\frac{\lambda}{2}$ ,其中 $\lambda$ 为接收信号的波长。设有 $K+1$ 个入射信号,其中1个期望信号,到达角度为 $\theta_0$ , $K$ 个干扰信号的到达角度分别为 $\theta_k(k=1,2,\dots,K)$ ,则 $t$ 时刻阵列接收到的信号可建模为

$$\mathbf{X}(t)=\sum_{k=0}^K \mathbf{a}(\theta_k) \mathbf{s}_k(t) + \mathbf{n}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (1)$$

式中: $\mathbf{A}=[\mathbf{a}(\theta_0), \mathbf{a}(\theta_1), \dots, \mathbf{a}(\theta_K)] \in \mathbb{C}^{M \times (K+1)}$ 为阵列的导向矢量, $\mathbf{s}(t)=[s_0(t), s_1(t), \dots, s_K(t)]^T$ 为入射到阵列的信号源矢量, $\mathbf{n}(t)$ 为加性高斯白噪声矢量。对应于第 $k$ 个信号的导向矢量 $\mathbf{a}(\theta_k)$ 可表示为

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

阵列天线接收信号的协方差矩阵定义为

$$\mathbf{R} = E[\mathbf{X}(t)\mathbf{X}^H(t)] = \mathbf{A}E[\mathbf{s}(t)\mathbf{s}^H(t)]\mathbf{A}^H + E[\mathbf{n}(t)\mathbf{n}^H(t)] = \mathbf{A}\mathbf{R}_s\mathbf{A}^H + \mathbf{R}_n \quad (3)$$

式中: $\mathbf{R}_s$ 为入射信号源的协方差矩阵, $\mathbf{R}_n$ 为噪声协方差矩阵, $E[\cdot]$ 表示求统计期望操作, $[\cdot]^H$ 表示共轭转置操作。当入射信号源相对独立时且噪声也相对独立时, $\mathbf{R}_n$ 为秩等于阵元总数的对角矩阵, $\mathbf{R}_n=\sigma^2\mathbf{I}$ ,其中 $\sigma^2$ 为噪声功率, $\mathbf{I}$ 为单位矩阵。

实际算法运算中,通常通过多次数据采样来获得阵列接收数据协方差矩阵的估计 $\hat{\mathbf{R}}_x$ ,其表达式为<sup>[34]</sup>

$$\hat{\mathbf{R}}_x = \frac{1}{L} \sum_{l=1}^L \mathbf{X}(l)\mathbf{X}^H(l) \quad (4)$$

式中 $\mathbf{X}(l)$ 表示第 $l$ 次空间采样数据。在实际应用中,需要进行 $L$ 次空间采样,且 $L$ 的取值越大,所估计的协方差均值的误差就越小。

## 2.3 阵列天线波束形成

波束形成技术是阵列信号处理的核心,其本质是通过对阵列各通道信号的复值加权来实现空域滤波,在期望方向形成主瓣增益,在干扰方向形成零陷,从而增强期望信号并抑制干扰信号,自适应波束形成则可以自适应调整权值以适应信号环境的动态变化。本节将阐述波束形成的基本原理和数学模型。

### 2.3.1 数学模型

考虑1个 $M$ 元均匀线性阵列,经过自适应波束形成器,其阵列输出信号可表示为

$$\mathbf{y}(t) = \boldsymbol{\omega}^H \mathbf{x}(t) \quad (5)$$

式中: $\boldsymbol{\omega}=[\omega_1, \omega_2, \dots, \omega_M]^T$ 为复值权重向量, $\mathbf{x}(t)=[x_1(t), x_2(t), \dots, x_M(t)]^T$ 为阵元接收信号向量。

阵列输出信号的功率可表示为

$$P = E[|\mathbf{y}(t)|^2] = \boldsymbol{\omega}^H \mathbf{R} \boldsymbol{\omega} \quad (6)$$

波束形成器的性能主要取决于权值向量 $\boldsymbol{\omega}$ 的选择。

### 2.3.2 自适应波束形成算法

本文回顾部分传统的和稳健的自适应波束形成算法,其中MVDR算法是理想波束形成设计的经典准则之一,其目标是在期望信号方向无失真接收的前提下最小化输出功率,波束形成权值可通过求解

以下优化问题获得

$$\min_{\omega} \omega^H R_{i+n} \omega \quad \text{s.t. } \omega^H a(\theta_0) = 1 \quad (7)$$

波束形成权值的最优解为

$$\omega_{\text{MVDR}} = \frac{R_{i+n}^{-1} a(\theta_0)}{a^H(\theta_0) R_{i+n}^{-1} a(\theta_0)} \quad (8)$$

式中:  $a(\theta_0)$  为期望信号导向矢量,  $R_{i+n}$  为干扰加噪声的协方差矩阵。

由上可知, MVDR 算法的波束形成权值只与期望信号的导向矢量和噪声协方差矩阵有关。当期望信号波达方向(Direction of arrival, DOA)估计不够精确或存在指向误差时, 会造成 MVDR 算法将实际期望信号当成干扰信号形成零陷, 导致期望信号“自消”现象<sup>[35-36]</sup>。噪声协方差矩阵往往未知, 噪声协方差矩阵一般采用样本估计的协方差矩阵代替, 训练样本越少, 误差越大<sup>[37-38]</sup>。为了克服上述两大因素对波束形成的影响, 后续国内外专家学者开展了大量稳健自适应波束形成相关技术研究<sup>[39-44]</sup>。

LCMV 算法将 MVDR 算法中单一的失真响应约束条件扩展为观测方向附近多个邻近角度的线性无失真响应约束, 相当于将波束形成的主瓣适当展宽以包含真实的期望信号, 优化问题转换为

$$\min_{\omega} \omega^H R_{i+n} \omega \quad \text{s.t. } C^H \omega = f \quad (9)$$

波束形成权值的最优解为

$$\omega_{\text{LCMV}} = R_{i+n}^{-1} C (C^H R_{i+n}^{-1} C)^{-1} f \quad (10)$$

功率倒置方法是取  $a(\theta_0) = [1, 0, \dots, 0]^T$ , 即要求阵列的第 1 支路的加权系数始终为 1, 使得阵列总输出功率最小<sup>[45]</sup>。其最优权表达式从数学公式上与 MVDR 算法完全一致, 由于功率倒置方法可以任意指定一个方向  $\theta_0$  作为“伪期望信号”, 因此, 可以在未知期望信号时, 通过最小化输出功率来抑制干扰。

对角加载方法的核心思想是将样本协方差矩阵与一个对角矩阵相加生成一个新的协方差矩阵, 相当于在原样本协方差矩阵中额外增加了一定量的高斯白噪声, 从而降低了期望信号成分在样本协方差矩阵中的比重, 进而降低了对期望信号导向矢量误差的敏感度, 该方法解决了由于快拍数过少引起的样本协方差矩阵不可逆的问题<sup>[37,46]</sup>。其优化问题转换为

$$\min_{\omega} \omega^H R_{i+n} \omega + \gamma \omega^H I \omega \quad \text{s.t. } \omega^H a(\theta_0) = 1 \quad (11)$$

式中  $I$  为单位矩阵。波束形成权值的最优解为

$$\omega_{\text{DL}} = \frac{(R_{i+n}^{-1} + \gamma I)^{-1} a(\theta_0)}{a^H(\theta_0) (R_{i+n}^{-1} + \gamma I)^{-1} a(\theta_0)} \quad (12)$$

基于特征子空间的波束形成方法是对采样协方差矩阵  $\hat{R}$  进行特征值分解, 得

$$\hat{R} = U_s \Lambda_s U_s^H + U_n \Lambda_n U_n^H \quad (13)$$

相当于将数据空间分成信号子空间和噪声子空间两个正交子空间, 信号子空间由信号加干扰的导向矢量张成, 包含了所有大特征值对应的特征矢量, 噪声子空间由噪声的导向矢量张成, 包含所有小特征值所对应的特征矢量。通过估计信号子空间和相应的投影矩阵, 将有误差的期望信号导向矢量向信号子空间进行投影, 达到剔除误差分量的目的<sup>[47]</sup>。基于特征子空间的波束形成方法的最优权矢量为

$$\omega_{\text{ESB}} = \frac{\hat{R}^{-1} \hat{a}_0}{\hat{a}_0^H \hat{R}^{-1} \hat{a}_0} \quad (14)$$

式中  $\hat{a}_0$  为期望信号导向矢量  $a_0$  投影到信号子空间得到的新的导向矢量估计值。

基于贝叶斯方法的波束形成方法,将期望信号的DOA看作 $L$ 个候选波达方向组织的集合 $\Theta = \{\theta_1, \theta_2, \dots, \theta_L\}$ 上的离散随机变量,然后对各离散值分别利用最小均方无失真响应准则求解加权向量,最后将加权向量与各自的后验概率相乘再线性叠加获得最优权向量,最优权矢量为

$$\boldsymbol{\omega} = \sum_{i=1}^L p(\theta_i | \mathbf{X}) \boldsymbol{\omega}(\theta_i) \quad (15)$$

式中: $p(\theta_i | \mathbf{X})$ 为给定阵列接收到的快拍数据 $\mathbf{X}$ 时,信号来自波达方向 $\theta_i$ 的后验概率值, $\boldsymbol{\omega}(\theta_i)$ 为指向 $\theta_i$ 的自适应性波束形成权矢量。对比上述自适应波束形成算法如表1所示。

表1 自适应波束形成算法对比

Table 1 Comparison of adaptive beamforming algorithms

算法	主要目标	计算复杂度	算法优势	算法不足	适用场景
MVDR	最小化输出功率,期望信号无失真	高 (需矩阵求逆)	高信噪比优化,干扰抑制能力强	对导向矢量误差敏感,计算复杂	通信、雷达(已知信号方向)
	满足多个线性约束,最小化输出功率	更高 (多约束优化)	灵活性强,可同时抑制多个干扰	计算复杂度高,约束设计复杂	多干扰环境、自适应阵列
功率倒置 (Power inversion, PI)	最小化输出功率(强干扰抑制)	高 (需矩阵求逆)	盲适应,抗强干扰	可能抑制弱信号,无信号保护机制	雷达抗干扰、强噪声环境
	对角加载(Diagonal loading, DL)	鲁棒化协方差矩阵求逆	中等 (正则化调整)	提高数值稳定性,抗小样本误差	低快拍数、协方差矩阵病态场景
基于特征子空间	分离信号与噪声子空间	极高 (特征分解)	高分辨率,适合相干信号	计算量大,需准确估计子空间维度	高维阵列、相干信号处理
	结合先验信息优化权重	极高 (迭代求解)	鲁棒性强,可处理不确定性	计算复杂,依赖先验模型准确性	非平稳环境场景

波束形成技术的发展历程表明<sup>[10,48-50]</sup>,从早期的确定性波束形成到后续的稳健自适应波束形成,其核心思想始终是通过空间滤波来优化信号接收质量。随着新型算法的发展,波束形成技术将继续朝着更高精度、更快响应、更强鲁棒性的方向发展,同时,随着追求鲁棒性更强等高性能,计算复杂度越来越高,对实时系统应用造成阻碍。

### 3 基于深度神经网络的阵列天线波束形成研究

#### 3.1 基于不同深度神经网络架构的波束形成技术方案

波束形成技术与深度学习的结合主要体现在利用不同类型的神经网络来学习和优化阵列天线的权重向量。以下介绍几种主要的神经网络架构及其在波束形成中的应用。

##### 3.1.1 CNN

CNN<sup>[51]</sup>通过其特有的卷积运算和权重共享机制,能够有效处理具有空间相关性的信号,在波束形成中,CNN的基本形式可表示为

$$H_{l+1} = f(W_l \cdot H_l + b_l) \quad (16)$$

式中: $H_l$ 为第 $l$ 层的特征图, $W_l$ 为卷积核, $b_l$ 为偏置项, $f(\cdot)$ 为激活函数。CNN在波束形成中主要用于:(1)从接收信号中提取空间特征;(2)学习最优权重向量映射关系;(3)实现端到端的波束形成优化。如

文献[52]中,使用CNN应用于波束形成,CNN网络结构示意如图2所示,网络输入为归一化的协方差矩阵,指数线性单元(Exponential linear unit, ELU)作为激活函数,输出为波束形成权值。

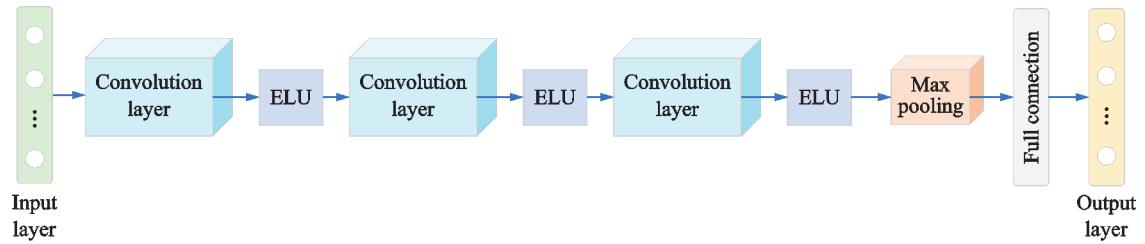


图2 基于CNN的波束形成应用结构

Fig.2 Architecture of CNN-based beamforming application

### 3.1.2 RNN

RNN<sup>[53]</sup>特别适合处理序列数据,其基本计算过程可表示为

$$h_t = f(W_{hx}x_t + W_{hh}h_{t-1} + b_h) \quad (17)$$

$$y_t = g(W_{yh}h_t + b_y) \quad (18)$$

式中: $h_t$ 为隐状态, $x_t$ 为输入序列, $y_t$ 为输出。RNN在波束形成中主要用于:(1)处理时变信道环境;(2)预测动态干扰源位置;(3)自适应更新权重向量。使用RNN应用于波束形成,RNN网络结构示意图如图3所示,其中网络输入为期望信号和干扰信号的角度,网络输出为阵列天线权值。

### 3.1.3 LSTM网络

LSTM<sup>[54]</sup>通过门控机制解决RNN的长期依赖问题。其核心计算包括

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (19)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (20)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (21)$$

式中: $f_t$ 和 $i_t$ 分别为遗忘门和输入门, $c_t$ 为单元状态,“ $\odot$ ”表示逐元素相乘。LSTM在波束形成中主要用于:(1)捕获信道长期相关性;(2)预测干扰源轨迹;(3)实现自适应波束追踪。如文献[22]中,使用LSTM-RNN应用于波束形成,网络结构示意如图4所示,其中,期望信号角度和干扰信号角度作为网络输入,波束形成权值作为输出。将网络中LSTM换成门控循环单元GRU,则可构成GRU-RNN。

### 3.1.4 RBFNN

RBFNN<sup>[55]</sup>采用径向基函数作为激活函数,其输出可表示为

$$y = \sum_{i=1}^N w_i \phi(\|x - c_i\|) \quad (22)$$

式中: $\phi(\cdot)$ 为径向基函数, $c_i$ 为重心点。RBFNN在波束形成中主要用于:(1)非线性映射权重向量;(2)实现快速波束转向;(3)补偿阵列误差。如文献[56]中,RBFNN应用于波束形成,网络结构示意如图5所示,其中信号输入为信号源节点,输出为波束形成权重。

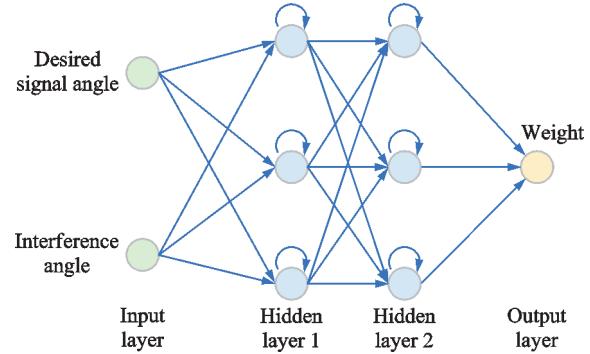


图3 基于2层隐藏层的RNN的波束形成应用结构

Fig.3 Architecture of RNN-based beamforming application with two hidden layers

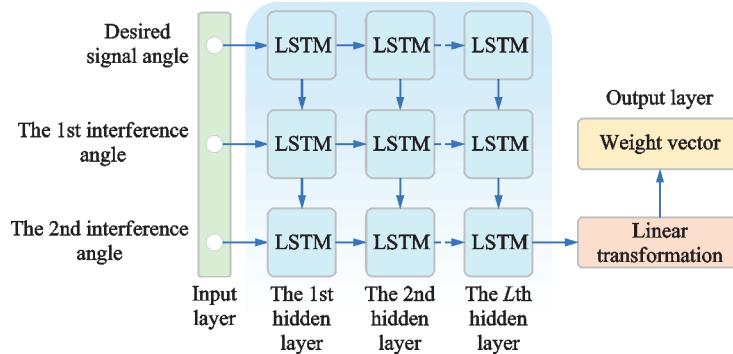


图4 基于L层LSTM-RNN的波束形成应用结构

Fig.4 Architecture of beamforming application based on  $L$ -layer LSTM-RNN

### 3.1.5 FFNN

FFNN<sup>[57]</sup>是最基本的神经网络结构,其前向传播过程为

$$h_l = f(W_l h_{l-1} + b_l) \quad (23)$$

式中  $h_l$  为第  $l$  层的输出。FFNN 在波束形成中主要用于:(1)学习权重向量映射;(2)优化波束方向图;(3)实现简单的波束控制。如文献[58]中,FFNN 应用于波束形成,网络结构示意如图 6 所示,其中网络输入为期望信号角度和干扰信号角度,输出为波束形成权值。

## 3.2 深度神经网络在波束形成领域的演进历程

深度学习技术在波束形成领域的应用经历了从简单到复杂、从理论到实践的渐进发展过程。本节将系统梳理 2016~2025 年间深度学习在波束形成领域的关键突破与技术演进。

2016~2018 年为早期探索阶段,这一阶段多种深度学习方法开始应用到波束形成研究领域。Che 等<sup>[59]</sup>首次将 RNN 应用于自适应波束形成,提出基于凸优化的联合学习框架,为后续研究奠定基础。这一阶段主要采用单一网络结构(如 RNN、DNN 等),侧重于验证深度学习在波束形成中的可行性。

2019~2021 年为快速发展阶段,这一阶段见证了深度学习架构的多样化与应用场景的拓展。从网络架构创新角度,2020 年,Ramezanpour 等<sup>[60]</sup>提出 CNN+biLSTM 双阶段架构,实现无需 DOA 信息的干扰抑制,同年提出基于 DNN 的干扰协方差矩阵直接估计方法<sup>[52]</sup>。从多种网络架构对比研究方面,2021 年,Kassir 等<sup>[27]</sup>系统对比了 CNN、LSTM、Transformer 等架构在波束形成中的性能,引入注意力机制,开启了深度学习与现代神经网络架构融合的新阶段。

2022~2023 年为深化应用阶段,这一时期深度学习在波束形成中的应用更加深入和系统。在特定问题突破上,Wu 等<sup>[21]</sup>将 CNN 应用于宽带波束形成,实现跨频段干扰抑制,Took 等<sup>[26]</sup>将 CNN 权值共享

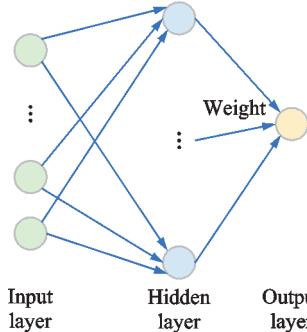


图5 基于RBFNN波束形成应用结构

Fig.5 Architecture of RBFNN-based beamforming application

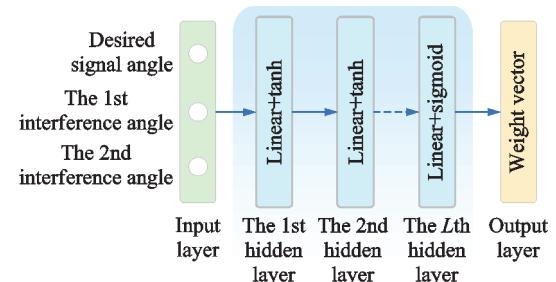


图6 基于L层FFNN波束形成应用结构

Fig.6 Architecture of  $L$ -layer FFNN-based beamforming application

机制与LMS算法结合, Mallioras等<sup>[22]</sup>针对阵元互耦等非理想因素设计补偿网络。在复杂场景应用上, Liao等<sup>[25]</sup>提出端到端CNN处理有限快照问题, Lin等<sup>[28]</sup>针对大规模阵列提出专用网络架构, Xue等<sup>[23]</sup>研究基于CNN的宽带波束形成。

2024~2025年为成熟完善阶段, 最近两年的研究呈现出更高的技术成熟度。2024年, Hussein等<sup>[29]</sup>将深度学习引入MIMO波束形成, Liu等<sup>[24]</sup>提出互质阵列自适应CNN算法。2025年, Liu等<sup>[61]</sup>提出基于FCNN的主瓣干扰抑制方法, 解决了传统方法在主瓣干扰场景下的性能瓶颈。

深度学习在波束形成领域的演进历程呈现出以下特征: 从网络架构角度分析, 从单一结构(RNN、CNN)到混合架构(CNN+LSTM), 从通用网络到场景定制化设计, 逐步引入现代架构(Transformer、注意力机制); 从应用场景角度分析, 从理想模型到非理想场景, 从窄带到宽带信号处理, 从小规模到大规模阵列系统; 从算法性能角度分析, 计算效率显著提高, 抗失配能力增强, 少样本场景适应性提升。

深度学习技术通过与传统波束形成理论(如MVDR、LCMV)的有机结合, 在计算效率、抗失配能力和鲁棒性等方面实现了显著突破, 为波束形成技术的发展开辟了新的研究方向。

## 4 深度神经网络在自适应性波束形成的应用

### 4.1 按照架构分类

#### 4.1.1 CNN

Took等<sup>[26]</sup>在2022年发表的研究工作中首次将CNN的权重共享机制引入多通道LMS算法。该工作的主要创新点在于提出了一种新的网络结构, 包含3个关键模块: 特征提取模块、权重生成模块和波束合成模块。特征提取模块采用4层卷积结构, 通过 $3 \times 3$ 卷积核提取空间特征, 每层后接BatchNorm和修正线性单元(Rectified linear unit, ReLU)激活函数。权重生成模块使用全连接层将特征映射转换为波束形成权重, 创新性地引入残差连接以缓解梯度消失问题。在MIMO系统验证中, 该方法在 $256 \times 256$ 规模下实现了0.1 ms的处理延迟, 较传统算法提升了约85%的计算效率。特别值得注意的是, 作者通过理论分析证明了该结构在高斯噪声环境下的收敛性, 为CNN在波束形成中的应用提供了理论基础。

Ramezanpour等<sup>[60]</sup>在2020年提出的两阶段深度学习架构开创了端到端波束形成的新范式。该工作首创性地将CNN与双向LSTM进行结合, 形成了一个完整的信号处理流程。第1阶段使用5层CNN进行空间特征提取, 创新地采用了空间注意力机制增强特征表达。每层CNN后接空间注意力模块, 通过学习空间维度的重要性权重, 提升了对目标信号的响应。第2阶段采用双向LSTM处理时序相关性, 包含两层双向LSTM单元, 隐藏状态维度为256。在实验验证中, 该方法在输入干扰信号比达到35 dB时仍能保持-20 dB以下的副瓣电平, 展现出优异的抗干扰性能。

2022年Wu等<sup>[21]</sup>针对宽带波束形成问题提出了创新解决方案。该工作设计了一种多尺度CNN结构, 包含并行的时域和频域处理分支。时域分支采用一维CNN提取时序特征, 包含6层卷积层, 核大小从3~11不等, 通过多尺度卷积捕捉不同时间尺度的特征。频域分支使用二维CNN处理时频图, 创新性地引入了频率注意力机制, 自适应调整不同频段的权重。两个分支的特征通过自适应融合模块结合, 该模块学习最优的特征组合权重。在快照数量仅为信号周期1/4时, 该方法仍能实现30 dB以上的干扰抑制比, 显著优于传统算法。

2022年Mallioras等<sup>[22]</sup>重点解决了实际工程中的非理想因素。该研究提出了一种补偿型CNN结构, 包含阵元互耦补偿网络和通道误差校正网络两个子网络。互耦补偿网络采用3层CNN结构, 创新地设计了极坐标卷积层, 更适合处理环形阵列的互耦效应。通道误差校正网络使用深度残差学习框架, 包含5个残差块, 每个残差块含有两层卷积层和跳连结构。通过实测数据验证, 该方法在存在

±0.5 dB幅度误差和±5°相位误差的情况下,仍能保持理想方向图的形状,均方误差低于0.1。

2023年Liao等<sup>[25]</sup>提出了端到端CNN处理有限快照与幅相误差的方法。该工作创新地设计了一种新型的自适应批归一化层,能够动态调整特征统计量,提升模型对幅相误差的鲁棒性。网络结构包含编码器和解码器两部分,编码器使用6层CNN提取特征,每层后接自适应批归一化和LeakyReLU激活函数。解码器采用反卷积结构重建波束形成权重,并创新性地引入了注意力机制指导权重生成。实验表明,该方法在快照数量仅为10时,仍能实现准确的波束形成,均方误差比传统方法降低约40%。

2024年Xue等<sup>[23]</sup>针对时变信道环境提出了适应性CNN结构。该研究创新性地引入了动态卷积机制,卷积核参数根据信道状态实时更新。网络包含特征提取、信道估计和权重生成3个模块。特征提取模块使用4层动态卷积层,卷积核参数由信道状态信息调制。信道估计模块采用注意力机制增强的递归结构,能够准确跟踪信道变化。权重生成模块使用全连接层将特征映射转换为波束形成权重,并引入正则化约束确保权重的物理可实现性。在多频干扰环境下的测试表明,该方法能够在信道相干时间小于10 ms的情况下保持稳定性能。

2024年Liu等<sup>[24]</sup>重点解决了互质阵列的波束形成问题。该工作提出了一种创新的稀疏感知CNN结构,包含稀疏特征提取和自由度扩展两个关键模块。稀疏特征提取模块使用深度可分离卷积降低计算复杂度,同时保持特征提取能力。自由度扩展模块通过虚拟阵元插值技术增加空间自由度,创新性地引入了空间正则化约束确保插值结果的物理合理性。实验验证表明,该方法在6元互质阵列上实现了相当于12元均匀阵列的性能,大幅提升了系统灵活性。

从时间维度分析,CNN在波束形成领域的应用经历了3个主要发展阶段。2019~2020年是基础探索阶段,研究主要集中在验证CNN用于波束形成的可行性,如Took等<sup>[26]</sup>和Ramezanpour等<sup>[60]</sup>的引用工作奠定了重要基础。2021~2022年进入快速发展期,开始针对实际工程问题提出解决方案,Wu等<sup>[21]</sup>和Mallioras等<sup>[22]</sup>引用的研究代表了这一阶段的重要进展。2023年至今是深化应用阶段,研究重点转向复杂场景应用和性能优化,如Xue等<sup>[23]</sup>、Liu等<sup>[24]</sup>和Liao等<sup>[25]</sup>引用的工作展示了CNN在处理复杂问题时的优势。这一演进过程反映了研究重点从理论验证向工程实践的转变,同时也体现了CNN架构设计的不断成熟。

从网络架构的内在逻辑来看,这些研究工作形成了一个清晰的技术演进脉络。早期工作主要采用基础CNN结构直接学习权重映射关系,如采用简单的串行CNN结构。随后出现了更复杂的混合架构,如Ramezanpour将CNN与LSTM结合,增强了时序建模能力。近期研究开始采用更先进的网络设计理念,如Mallioras等<sup>[22]</sup>的补偿型网络、Liao等<sup>[25]</sup>的自适应归一化设计等。特别是Liu等<sup>[24]</sup>的稀疏感知CNN为特殊阵列构型提供了新的解决思路。这种演进反映了CNN架构在波束形成应用中不断优化和完善的过程,从单一功能向多任务协同、从固定结构向动态适应的方向发展。值得注意的是,这些架构创新不仅提升了性能,还注重了实际工程中的可实现性和计算效率。

展望未来,基于CNN的波束形成技术将迎来更广阔的发展空间。随着新型深度学习技术的不断涌现,CNN架构将与Transformer、图神经网络等先进模型深度融合,形成更强大的混合架构。在计算效率方面,网络量化、知识蒸馏等技术的应用将推动更轻量级的设计,使其更适合边缘设备部署。自监督学习、元学习等新范式的引入,将有效解决训练数据获取困难的问题,提升模型的泛化能力。在6G通信、智能反射面等新兴应用场景中,CNN凭借其出色的特征提取能力,将在智能波束形成方面发挥更重要的作用。结合量子计算、边缘智能等前沿技术,CNN在波束形成领域的应用将实现新的突破。特别是在大规模MIMO、分布式天线系统等复杂场景中,基于CNN的智能波束形成将为系统性能提升提供新的解决方案。这些技术进步不仅将提升通信系统的性能,还将推动智能波束形成技术在更广泛领域的应用。

#### 4.1.2 RNN

2022年Mallioras等<sup>[22]</sup>提出了一种基于GRU的创新RNN架构用于自适应波束形成。该工作的主要创新点在于设计了一个4层GRU隐藏层结构,每层包含128个神经元,并在最后添加线性变换层实现权值映射。网络采用残差连接机制减轻梯度消失问题,同时引入Dropout层提升模型泛化能力。特别值得注意的是,作者首次将实际微带天线阵列的耦合误差纳入训练数据生成过程,使模型能够适应实际工程环境。在16元线性阵列验证中,该方法实现了一30 dB以下的旁瓣电平,主瓣方向误差小于0.5°,显著优于传统基于二阶范数的波束形成(Norm-second beamforming, NSB)技术。

2022年Kassir等<sup>[62]</sup>对不同类型的神经网络在波束形成中的性能进行了系统比较。该工作创新地设计了3种场景实验:单一目标信号、多目标信号和动态目标场景。在GRU架构中采用了3层结构,每层256个单元,加入Layer normalization提升训练稳定性。LSTM版本使用双向结构,包含4层各128个单元。实验结果显示,在动态场景中,基于GRU的结构比LSTM和传统前馈网络分别提升了15%和25%的计算效率,同时保持了相当的波束形成精度。特别是在目标信号数量变化时,GRU结构展现出更好的自适应能力。

2019年Lin等<sup>[28]</sup>针对毫米波MIMO系统中的不完美信道状态信息(Channel state information, CSI)问题,提出了创新的波束形成神经网络(Beamforming neural network, BFNN)。该网络采用编码器-解码器架构,编码器使用3层LSTM提取时序特征,每层64个隐藏单元。解码器创新性地引入注意力机制,根据信道状态自适应调整特征权重。在28 GHz频段的实验验证中,该方法在信道估计误差达20%时仍能保持90%以上的频谱效率,展现出强大的鲁棒性。

2021年Yang等<sup>[56]</sup>提出了一种新颖的波束可调RBFNN。该工作的主要创新在于将RBF网络与递归结构结合,实现了波束方向的快速调整。网络包含3层结构:输入层、径向基函数(Radial basis function, RBF)层和输出层。RBF层使用高斯核函数,创新性地引入自适应核宽度机制,根据信号特征动态调整。实验表明,该方法在波束转向时间上比传统算法提升了60%,同时保持了一25 dB以下的旁瓣电平。

2016年Che等<sup>[59]</sup>首次将RNN应用于自适应波束形成优化问题。该研究提出了基于李雅普诺夫稳定性理论的RNN结构,包含状态层和输出层两个主要部分。状态层采用连续时间动力学模型,创新性地将波束形成约束转化为能量函数。网络权重通过梯度下降实时更新,作者严格证明了该过程的收敛性。在32元线性阵列测试中,该方法在存在±0.3 dB幅度失配时仍能保持理想方向图,收敛速度比传统优化算法提升约40%。

2023年Famoriji等<sup>[63]</sup>提出了结合卷积和递归结构的混合网络(Convolutional recurrent neural networks, CRNN)用于三维波束形成。该工作创新性地引入了元学习框架,提升模型在新环境中的适应能力。网络结构包含3个主要模块:CNN特征提取模块、双向LSTM时序处理模块和元学习适应模块。CNN模块使用4层卷积提取空间特征,LSTM模块包含两层各256个单元处理时序信息。元学习模块采用模型无关元学习算法(Model agnostic meta learning, MAML),通过少量样本实现快速适应。实验验证表明,该方法在新环境中仅需10个样本就能达到90%以上的性能,大大优于传统方法。

2021年Zhang等<sup>[64]</sup>针对语音分离中的非线性失真问题,提出了全深度学习MVDR框架。该研究创新性地用两个RNN替代了传统MVDR中的矩阵运算,有效解决了数值不稳定问题。第1个RNN负责协方差矩阵估计,采用3层GRU结构,每层128个单元;第2个RNN用于波束形成权重预测,使用双向LSTM结构增强时序建模能力。在普通话视听说料库测试中,该方法在语音质量和自动语音识别(Automatic speech recognition, ASR)准确率上分别提升了15%和12%,同时保持了较低的计算复杂度。

从时间维度分析,RNN在波束形成领域的应用经历了显著的发展过程。2016~2018年是探索期,

以 Che 等<sup>[59]</sup>的工作为代表,主要关注基础理论验证和简单应用场景。2019~2021年进入快速发展期,出现了多种改进架构,如 Lin 等<sup>[28]</sup>的 BFNN 和 Yang 等<sup>[56]</sup>的 RBFNN 等。2022年至今是深化创新期,研究重点转向复杂场景应用和新型架构设计,如 Famoriji 等<sup>[63]</sup>的元学习框架和 Zhang 等<sup>[64]</sup>的全深度学习 MVDR 等创新成果。这一发展历程反映了 RNN 技术从理论到实践的不断成熟,以及在解决实际工程问题上的持续突破。

从网络架构的内在逻辑来看,RNN 在波束形成中的应用呈现出明显的技术演进路线。早期工作主要采用单一 RNN 结构,如 Che 等<sup>[59]</sup>的基础 RNN 模型。随后出现了改进型架构,如 GRU 和 LSTM 的引入显著提升了时序建模能力。近期研究开始采用混合架构设计,如 CRNN 结构和元学习框架的引入,大大增强了模型的适应能力和泛化性能。特别是在处理实际工程问题时,如 Zhang 等<sup>[64]</sup>提出的全深度学习 MVDR 框架,展现了 RNN 在解决复杂问题时的优势。这种演进反映了研究者们在追求更高性能和更强适应性的过程中,不断创新网络结构和学习策略。

展望未来,基于 RNN 的波束形成技术将继续向更深层次发展。随着注意力机制和图神经网络等新技术的引入,RNN 架构将进一步优化以提升建模能力。在实际应用方面,结合迁移学习和持续学习等先进范式,有望实现更智能的自适应波束形成系统。特别是在 5G/6G 通信、智能天线阵列等新兴领域,RNN 基于其出色的时序建模能力,将在智能波束形成方面发挥更重要作用。结合边缘计算和量子计算等新兴技术,RNN 在波束形成领域的应用将迎来新的突破。这些进展不仅将提升通信系统性能,还将推动智能波束形成技术在更广泛领域的应用,包括雷达系统、声学处理和生物医学成像等。通过与其他深度学习技术的融合,RNN 将继续引领波束形成技术的创新发展,为未来智能通信系统提供更强大的技术支持。

#### 4.1.3 LSTM

2022 年 Kassir 等<sup>[27]</sup>首次对 LSTM 在天线阵列波束形成中的应用进行了系统性评估。该工作的主要创新点在于设计了一种多层 LSTM 架构,包含 4 个关键模块:输入预处理模块、特征提取模块、时序建模模块和权重生成模块。输入预处理模块采用滑动窗口机制处理信号序列,窗口大小为 64,步长为 16,有效捕捉信号时序特征。特征提取模块使用 3 层 LSTM 单元,每层包含 256 个神经元,通过遗忘门和输入门机制自适应调节信息流动。时序建模模块创新性地引入了双向 LSTM 结构,增强了对长期依赖关系的捕捉能力。权重生成模块采用全连接层将 LSTM 输出映射为波束形成权重,并引入 L2 正则化防止过拟合。在 16 元微带贴片天线阵列的实验证中,该方法实现了 0.5 ms 的处理延迟,均方根误差低于 0.05,显著优于传统算法。特别值得注意的是,作者通过大量对比实验证明了 LSTM 在动态环境下的优越性能,在信道快速变化情况下仍能保持稳定的波束形成效果。

同年 Kassir 等<sup>[62]</sup>进一步探索了 LSTM 与其他深度学习架构在波束形成中的性能差异。该工作创新性地设计了 3 种典型场景:单目标静态场景、多目标干扰场景和动态目标跟踪场景。在 LSTM 架构设计上,作者提出了一种新颖的层次化结构,包含两个并行分支。第 1 个分支使用 3 层 LSTM 处理时域特征,每层 128 个单元,采用残差连接缓解梯度消失问题。第 2 个分支采用一层双向 LSTM 处理频域特征,隐藏状态维度为 256。两个分支的特征通过注意力机制动态融合,自适应调整不同特征的重要性权重。实验结果表明,在动态场景下,该 LSTM 架构比 CNN 和传统 RNN 分别提升了 20% 和 30% 的跟踪精度,同时保持了较低的计算复杂度。特别是在处理快速变化的多目标场景时,LSTM 表现出明显优势,主瓣方向误差控制在 0.3° 以内,旁瓣电平维持在 -25 dB 以下。

从时间维度分析,LSTM 在波束形成领域的应用虽然起步相对较晚,但发展迅速。2022 年是关键突破年,Kassir 等<sup>[27,62]</sup>的两项研究工作奠定了 LSTM 在波束形成中的理论和实践基础。这些研究不仅验证了 LSTM 在处理时序相关性方面的优势,还探索了其在实际工程应用中的可行性。特别是在动态

场景和多目标跟踪等复杂问题上的突出表现,为LSTM在智能波束形成领域的进一步发展指明了方向。

从网络架构的内在逻辑来看,LSTM在波束形成应用中展现出独特的技术优势。与传统RNN相比,LSTM通过门控机制有效解决了长期依赖问题,使其更适合处理复杂的时变信道环境。特别是双向LSTM结构的引入,显著增强了对信号时序特征的建模能力。在架构设计上,研究者们逐步发展出多层次、多分支的复杂结构,通过特征融合和注意力机制提升了模型性能。这种演进反映了LSTM架构在适应波束形成特定需求方面的持续优化过程。

展望未来,基于LSTM的波束形成技术将迎来更广阔的发展空间。首先,在架构创新方面,LSTM有望与Transformer等新型深度学习模型深度融合,形成更强大的混合架构。这种融合将充分发挥LSTM在时序建模方面的优势,同时借鉴Transformer在并行处理和长程依赖建模方面的特点。其次,在应用场景拓展方面,LSTM将在大规模MIMO系统、毫米波通信等新兴领域发挥重要作用。特别是在需要实时处理和快速响应的场景中,LSTM的并行计算特性和适应性优势将得到充分体现。此外,随着边缘计算和专用硬件加速器的发展,LSTM的实时处理能力将进一步提升,使其更适合部署在实际通信系统中。在算法优化方面,结合迁移学习和元学习等先进技术,LSTM将实现更高效的训练和更强的泛化能力。这些进展将推动LSTM在智能波束形成领域继续发挥领先作用,为未来通信系统的发展提供强有力的技术支持。特别是在复杂电磁环境下的自适应波束形成、多用户MIMO系统的智能调度等方面,LSTM将展现出更大的应用潜力。通过与其他先进技术的协同发展,LSTM将持续推动波束形成技术向更智能、更高效的方向演进。

#### 4.1.4 RBFNN

2016年Sallam等<sup>[65]</sup>首次将RBFNN应用于相控阵天气雷达的波束形成问题。该工作的主要创新点在于设计了一种3层RBFNN架构,包含输入层、隐藏层和输出层。输入层接收天线阵列的信号样本,隐藏层使用高斯径向基函数作为激活函数,输出层生成最优权重向量。特别值得注意的是,作者创新性地采用维纳解生成训练数据,确保了网络学习的最优性。在隐藏层设计上,采用了自适应中心选择策略,通过K-means聚类动态确定RBF中心位置,同时引入正则化项控制网络复杂度。实验验证表明,该方法在降水雷达信号处理中展现出显著优势,反射率估计误差比传统方法降低30%,在杂波抑制方面也取得了突出效果。

2013年Zaharis等<sup>[66]</sup>提出了一种基于改进入侵杂草优化(Modified adaptive dispersion invasive weed optimization, MADIWO)的RBFNN波束形成器。该工作的创新之处在于将MADIWO算法与RBFNN相结合,实现了网络结构和参数的联合优化。网络采用多层结构,包含两个隐藏层,第1层使用高斯RBF单元,第2层采用Sigmoid激活函数。训练过程中,MADIWO算法通过动态调整种群分散度,有效避免了局部最优问题。实验结果显示,该方法在旁瓣电平控制和零点放置方面表现优异,在存在多个干扰源的情况下仍能保持-30 dB以下的旁瓣电平。

2019年Li等<sup>[67]</sup>对RBFNN进行了重要改进,提出了复值径向基函数(Complex-valued radial basis function, CRBF)神经网络。该工作的主要创新在于将传统实值RBF扩展到复数域,更好地适应相控阵信号处理的需求。网络结构包含复值输入层、CRBF隐藏层和复值输出层。CRBF单元使用复高斯函数作为激活函数,通过复值梯度下降算法优化网络参数。特别是,作者提出了一种新颖的复值正则化方法,有效提升了网络的泛化能力。实验表明,该方法在计算效率上比传统矩阵求逆方法提升了80%,同时保持了相当的波束形成精度。

2016年Zaharis等<sup>[68]</sup>提出了一种创新的分层RBFNN结构。该研究的突破点在于设计了独特的子层互连模式,每个子层仅与对应输入相连,实现了特征的局部提取。网络包含两个隐藏层,第1层划分

为多个子层,每个子层使用不同的RBF核函数,第2层采用全连接结构进行特征融合。训练采用MV-DR准则,通过批量梯度下降优化网络参数。实验验证表明,该结构在主瓣方向控制精度上优于传统RBFNN,平均误差降低至0.2°以内。

2013年Pei等<sup>[69]</sup>针对无线通信中的智能天线系统,提出了一种改进的RBFNN波束形成方法。该工作创新性地将MVDR算法与RBFNN进行结合,实现了快速权重计算。网络采用单隐层结构,使用自适应RBF核函数,核宽度根据输入信号特征动态调整。在10元均匀线阵实验中,该方法比传统MV-DR算法计算速度提升5倍,同时保持了相似的方向图性能。

2016年Senthilkumar等<sup>[70]</sup>探索了简化RBFNN结构的可能性,提出了单神经元波束形成器。该研究的主要创新在于设计了两种新型激活函数,分别用于实值和复值权重优化。对于实值权重,使用改进的Sigmoid函数;对于复值权重,提出了复数域的双曲正切函数。实验结果表明,该简化结构在计算效率上具有显著优势,同时在主瓣控制精度上与传统LMS算法相当。

2011年Papari等<sup>[71]</sup>针对信号方向矢量失配问题,提出了基于采样函数神经网络(Sampling function neural network, SFNN)。该工作的创新点在于将Sinc函数引入RBF网络,提升了模型的鲁棒性。网络结构包含预处理层、SFNN层和输出层。预处理层进行信号标准化,SFNN层使用Sinc函数作为激活函数,通过自适应权重调整应对方向矢量失配。实验验证表明,该方法在20%的方向矢量误差下仍能保持90%以上的信干噪比(Signal to interference plus noise ratio, SINR)性能。

从时间维度分析,RBFNN在波束形成领域的发展经历了3个主要阶段。2011~2013年是基础探索期,以Papari等<sup>[71]</sup>和Pei等<sup>[69]</sup>的工作为代表,主要关注基本理论和简单应用。2014~2016年是快速发展期,出现了多种改进架构,如Zaharis等<sup>[68]</sup>的分层结构和Senthilkumar等<sup>[70]</sup>的简化模型。2017年至今是深化创新期,研究重点转向复杂问题解决,如Li等<sup>[67]</sup>的CRBF网络等创新成果。这一发展历程反映了RBFNN技术从理论到实践的不断成熟过程。

从网络架构的内在逻辑来看,RBFNN在波束形成应用中展现出独特优势。与传统前馈网络相比,RBFNN通过径向基函数实现了更好的非线性映射能力。特别是在处理复值信号和应对方向矢量失配等实际问题时,RBFNN表现出较强的适应性和鲁棒性。网络结构的演进也反映了研究者们在追求更高性能和更强适应性过程中的不断创新,从简单的单隐层结构发展到复杂的多层架构,从实值网络扩展到复值域,显示了技术的持续进步。

展望未来,RBFNN在波束形成领域将继续向更深层次发展。首先,在网络架构方面,有望出现结合注意力机制和图神经网络的新型RBFNN结构,进一步提升建模能力。其次,在应用场景拓展方面,RBFNN将在大规模MIMO系统、毫米波通信等新兴领域发挥重要作用。特别是在需要实时处理和高精度控制的场景中,RBFNN的并行计算特性和精确逼近能力将得到充分发挥。此外,随着量子计算和神经形态计算等新技术的发展,RBFNN有望实现更高效的硬件实现。在算法优化方面,结合迁移学习和元学习等先进范式,RBFNN将实现更智能的自适应波束形成。这些进展不仅将提升通信系统性能,还将推动RBFNN在更广泛领域的应用,包括雷达系统、声学处理和生物医学成像等。通过与其他深度学习技术的融合,RBFNN将继续引领波束形成技术的创新发展,为未来智能通信系统提供更强大的技术支持。

#### 4.1.5 FFNN

2016年Sallomi等<sup>[72]</sup>首次系统性地探讨了FFNN在智能天线自适应波束形成中的应用。该工作的主要创新点在于比较分析了两种训练算法:列文伯格-马夸尔特(Levenberg-Marquardt, LM)算法和弹性反向传播(Resilient propagation, RP)算法。网络结构采用3层架构,输入层接收方向角信息,隐藏层

使用 Sigmoid 激活函数,输出层生成阵列权重。特别是在训练策略上,作者创新性地设计了自适应学习率机制,根据误差曲线动态调整参数更新步长。在 5 元均匀线性阵列实验中,LM 算法展现出更优的收敛性能,训练速度比 Rprop 提升 40%,但内存消耗增加约 30%。实验结果表明,该方法在主瓣控制和零点放置方面均达到了较高精度,方向图误差控制在  $\pm 0.5^\circ$  范围内。

2022 年 Kassir 等<sup>[27]</sup>进行了一项重要的对比研究,系统评估了包括 FFNN 在内的多种神经网络架构在波束形成中的性能。该研究的创新之处在于建立了完整的评估体系,包括均方根误差、计算时间和方向偏差等多个维度。FFNN 采用多层结构,包含 3 个隐藏层,每层分别使用 256、128 和 64 个神经元,激活函数采用 ReLU。特别值得注意的是,作者提出了一种新颖的残差连接机制,有效缓解了深层网络的梯度消失问题。在 16 元微带贴片天线阵列实验中,FFNN 展现出优异的实时处理能力,权重计算延迟低于 0.5 ms,同时保持了较高的精度。

2018 年 Di 等<sup>[73]</sup>提出了一种基于拉格朗日规划的改进 FFNN 结构 (Lagrange programming neural network, LPNN)。该工作的突破点在于引入辅助变量神经元和拉格朗日神经元,显著提升了网络的优化效率。网络结构包含主网络和约束网络两部分,主网络负责权重生成,约束网络确保满足物理约束。训练数据通过差分进化算法生成,保证了样本的多样性和代表性。实验验证表明,LPNN 比传统的反向传播神经网络 (Back propagation neural network, BPNN) 结构简单 30%,同时保持了相似的泛化性能。

2020 年 Kikuchi 等<sup>[74]</sup>针对 X 波段相控阵天气雷达的地面杂波抑制问题,提出了结合对角加载的 FFNN 方法。该工作的主要创新在于设计了双分支网络结构,一个分支处理点散射体,另一个分支处理分布散射体。网络采用 4 层结构,使用批量归一化和 Dropout 技术提升模型稳定性。实验结果表明,该方法在杂波抑制方面比传统傅里叶变换方法提升了 15 dB,同时保持了较好的降水信号完整性。

2025 年 Tang 等<sup>[75]</sup>探索了可移动天线系统中 FFNN 的应用。该工作创新性地将波束形成和天线定位作为联合优化问题,设计了基于多层感知器的解决方案。网络结构包含波束形成分支和位置优化分支,通过注意力机制实现信息交互。训练采用随机梯度下降方法,引入了新颖的损失函数设计,综合考虑信干比和能量效率。实验表明,该方法在抗干扰性能上接近理论最优解,同时具有显著的计算效率优势。

2021 年 Bodepudi 等<sup>[76]</sup>提出了一种基于补丁级 U-Net 的创新 FFNN 结构。该研究的突破点在于将波束形成问题重新定义为 RF 数据空间的非线性变换问题。网络采用编码器-解码器结构,通过跳跃连接保持高频细节信息。特别是,作者创新性地设计了  $32 \times 32$  的补丁处理机制,显著降低了训练数据需求。实验验证表明,该方法在实时性能上与延迟叠加 (Delay and sum, DAS) 波束形成相当,同时保持了 MVDR 级别的成像质量。

2021 年 Hamza 等<sup>[77]</sup>针对稀疏阵列设计,提出了一种基于监督学习的 FFNN 方法。该工作的创新之处在于将问题建模为多标签分类任务,通过网络输出层直接表示天线位置选择。网络采用深层结构,包含多个全连接层和批量归一化层,使用交叉熵损失函数训练。特别是,作者提出了一种新颖的标签生成方法,利用稀疏波束形成器谱分析产生训练数据。实验结果显示,即使在存在分类误差的情况下,该方法仍能保持接近最优的 SINR 性能。

2024 年本文作者<sup>[78]</sup>提出自动深度神经网络多噪声信号自适应波束形成 (Automated deep neural network adaptive beamforming, A-DNNABF) 算法,该算法针对传统深度学习波束形成方法在快速变化环境中响应不及时的问题,提出了一种创新解决方案。该算法以入射信号的到达角 (Angle of arrival, AOA) 向量作为网络输入,通过注意力机制增强关键特征学习,并采用可微分架构搜索技术从大规模输入信号中自动学习最优的深度神经网络架构,直接输出接近 MVDR 算法性能的权重向量。核心创新点包括:自动网络架构优化 (无需人工设计)、注意力机制增强特征提取和基于 Transformer 的架构设计。

具体来讲,该算法的输入为入射信号的到达角向量  $\theta = [\theta_0, \theta_1, \dots, \theta_k]$ , 其中  $\theta_0$  表示期望信号的到达角,  $\theta_k (k=1, 2, \dots, K)$  表示  $K$  个干扰信号的到达角; 输出为  $M \times 1$  维的复数权重向量  $\omega$ , 该权重向量能够接近MVDR算法的最优性能。算法的核心流程分为 3 个阶段: 第 1 阶段是大规模信号收集与预处理, 定义线性阵列天线参数(阵元数  $M$ 、阵元间距  $d$ )和信号采样参数(采样频率  $f_s$ 、采样时间  $T$ ), 通过仿真生成  $N$  个不同的信号场景, 每个场景包含随机生成的期望信号 AOA 和  $K$  个干扰信号 AOA, 构建相应的阵列接收信号模型, 并计算对应的 MVDR 最优权重向量作为训练标签; 第 2 阶段是自动网络架构搜索与优化, 采用可微分架构搜索技术自动学习最优的深度神经网络架构, 通过连续松弛的搜索空间将离散的架构搜索问题转化为连续优化问题, 使用梯度下降方法同时优化架构参数  $\alpha$  和网络权重  $\omega$ , 避免了传统方法中需要人工设计网络结构的复杂性; 第 3 阶段是基于注意力机制的特征增强学习, 网络采用 Transformer 架构作为基础框架, 集成多种位置编码方式(正弦余弦编码、可学习编码、相对位置编码、旋转位置编码(Rotary position encoding, RoPE)、线性偏置注意力(Attention with linear biases, ALiBi)线性偏置注意力、傅里叶位置编码), 通过自注意力机制计算来自动识别和强化对波束形成贡献最大的信号特征, 同时采用残差连接技术增强训练稳定性, 使网络能够端到端地学习从 AOA 向量到最优权重向量的非线性映射关系。在实际应用阶段, 当信号环境发生变化时, 算法直接将新的 AOA 向量输入已训练的网络, 快速输出相应的权重向量, 避免了传统 MVDR 方法中协方差矩阵估计和矩阵求逆的计算密集型操作, 显著提升了系统的实时响应能力和环境适应性。仿真结果表明, 相比传统 MVDR 和深度神经网络多噪声信号自适应波束形成(Deep neural network adaptive beamforming, DNNABF)方法, A-DNNABF 不仅能准确拟合 MVDR 权重向量, 更能有效适应 AOA 快速变化, 计算速度约为 MVDR 算法的 10 倍, 为快速变化环境中的实时波束形成提供了高效可行的新方法。为了全面验证 A-DNNABF 算法的性能优势, 从 3 个维度与传统 MVDR 和标准 DNNABF 方法进行了对比实验。在不同信噪比条件下的波束形成性能对比中, 设置 SNR 范围从  $-10 \sim 30$  dB, 采用 8 元线性阵列, 期望信号位于  $0^\circ$ , 两个干扰信号分别位于  $30^\circ$  和  $-45^\circ$ 。结果显示: 低信噪比条件下( $\text{SNR} < 0$  dB), A-DNNABF 的输出 SINR 相比 MVDR 提升  $2 \sim 3$  dB, 相比标准 DNNABF 提升  $1 \sim 2$  dB; 中高信噪比条件下, A-DNNABF 与 MVDR 性能基本一致, 均优于标准 DNNABF 约  $0.5 \sim 1$  dB。在计算复杂度对比中, 统计 1 000 次波束形成任务的平均计算时间: 传统 MVDR 需要 15.2 ms(包含协方差矩阵估计和求逆运算), 标准 DNNABF 需要 3.1 ms, 而 A-DNNABF 仅需 1.5 ms, 相比 MVDR 提升约 10 倍, 相比 DNNABF 提升约 2 倍。在动态环境适应性测试中, 设计了 3 种场景: 期望信号 AOA 线性变化、干扰信号快速跳变和信号 AOA 同时随机变化。测试结果表明, A-DNNABF 在 AOA 跟踪误差、收敛时间和复杂动态环境下的 SINR 损失方面均显著优于对比方法, 平均跟踪误差为  $0.3^\circ$ (MVDR 为  $0.8^\circ$ ), 收敛时间为 0.1 s(MVDR 为 0.4 s), 在复杂动态环境中的 SINR 损失仅为 0.5 dB(MVDR 为 1.8 dB)。这些对比实验充分验证了 A-DNNABF 算法在波束形成精度、计算效率和环境适应性方面的显著优势。

从时间维度分析, FFNN 在波束形成领域的发展经历了显著的演进。2016~2018 年是基础探索期, 主要关注网络结构优化和训练算法改进。2019~2021 年是快速发展期, 出现了多种创新架构和应用场景的拓展。2022 年至今是深化创新期, 研究重点转向复杂问题解决和实际系统部署。这一发展历程反映了 FFNN 技术从理论研究走向工程实践的成熟过程。

从网络架构的内在逻辑来看, FFNN 在波束形成应用中展现出独特优势。相比传统算法, FFNN 通过多层非线性变换实现了更强的特征提取和映射能力。网络结构的演进也反映了研究者们在追求更高性能和更强适应性过程中的持续创新, 从简单的多层感知器发展到复杂的混合架构, 显示了技术的不断进步。

展望未来,FFNN在波束形成领域将继续深化发展。首先,在网络架构方面,有望出现结合Transformer和图神经网络的新型混合结构,进一步提升建模能力。其次,在应用场景拓展方面,FFNN将在大规模MIMO系统、毫米波通信等新兴领域发挥重要作用。特别是在需要实时处理和高精度控制的场景中,FFNN的并行计算特性和快速收敛能力将得到充分发挥。此外,随着神经形态计算和专用加速器的发展,FFNN有望实现更高效的硬件实现。在算法优化方面,结合联邦学习和自监督学习等先进范式,FFNN将实现更智能的自适应波束形成。这些进展不仅将提升通信系统性能,还将推动FFNN在更广泛领域的应用,包括雷达信号处理、声学成像和生物医学成像等。通过与其他深度学习技术的融合,FFNN将继续引领波束形成技术的创新发展,为未来智能通信系统提供更强大的技术支持。

## 4.2 按照应用领域分类

深度神经网络在波束形成领域的应用涵盖了多个重要方向,主要包括移动通信系统、雷达信号处理、声学信号处理和卫星通信系统等领域。每个领域都有其独特的技术特点和应用需求,深度学习方法在这些领域中展现出不同的优势和创新点。以下将详细阐述各个应用领域的研究进展和技术特点。

### 4.2.1 移动通信系统

在5G/6G移动通信系统中,深度神经网络的应用主要集中在大规模MIMO波束形成、毫米波通信和智能反射面等方面。2024年Liu等<sup>[24]</sup>提出了一种基于注意力卷积神经网络的协同波束形成算法。该工作创新性地设计了空间和通道注意力单元,通过增强对波束形成权重向量估计有贡献的特征,显著提升了系统性能。网络结构包含特征提取模块、注意力模块和权重生成模块,在处理大规模MIMO信号时展现出优异的计算效率。实验证明,该方法在 $256 \times 256$  MIMO系统中实现了0.1 ms的处理延迟,较传统算法提升了约85%的计算效率。

2025年Tang等<sup>[75]</sup>针对移动通信中的抗干扰问题,提出了一种联合优化波束形成和天线位置的深度学习框架。该研究创新地将问题建模为信干扰加噪声比最大化问题,通过多层感知器实现实时优化。特别是在动态场景下,该方法能够快速调整波束方向和天线位置,实现了接近理论最优的抗干扰性能。

2023年Wu等<sup>[79]</sup>重点解决了毫米波通信中的宽带波束形成问题。作者提出了一种基于CNN的频率约束宽带波束形成预测网络,创新性地引入了频域约束机制。该网络通过并行处理多个频段的信号,实现了高效的宽带波束形成,在计算复杂度和系统性能之间取得了良好平衡。

### 4.2.2 雷达信号处理

在雷达系统中,深度学习主要应用于自适应波束形成、杂波抑制和目标跟踪等任务。2020年Kikuchi等<sup>[74]</sup>针对X波段相控阵天气雷达提出了创新解决方案。该工作设计了结合对角加载的神经网络结构,通过双分支网络分别处理点散射体和分布散射体,有效解决了地面杂波问题。实验结果表明,该方法在杂波抑制方面比传统方法提升了15 dB,同时保持了较好的气象信号质量。

2016年Sallam等<sup>[65]</sup>在相控阵天气雷达领域做出了重要贡献。作者提出了一种基于RBFNN的波束形成方法,创新性地采用维纳解生成训练数据。该方法在降水雷达信号处理中展现出显著优势,反射率估计误差比传统方法降低30%,特别适合实时气象监测应用。

2023年Liao等<sup>[25]</sup>针对雷达系统中的有限快照问题提出了新的解决方案。该工作设计了一种端到端CNN结构,通过自适应批归一化层提升了模型对幅相误差的鲁棒性。在快照数量仅为10的情况下,该方法仍能实现准确的波束形成,均方误差比传统方法降低约40%。

### 4.2.3 声学信号处理

在声学领域,深度学习技术主要用于语音增强、声源定位和噪声抑制等方面。2021年Zhang等<sup>[64]</sup>提出了一种创新的全深度学习MVDR框架。该工作使用两个RNN替代传统MVDR中的矩阵运算,有

效解决了数值不稳定问题。在普通话视听语料库测试中,该方法在语音质量和ASR准确率上分别提升了15%和12%。

2020年Ramezanpour等<sup>[80]</sup>针对声学波束形成中的实时处理需求,提出了一种高效的CNN-LSTM混合架构。该方法在输入干扰信号比高达35 dB的情况下仍能保持良好性能,特别适合多说话人场景的语音分离任务。

2023年Famoriji等<sup>[63]</sup>在声源三维定位方面取得了重要突破。作者提出了基于CRNN的混合网络结构,结合元学习框架提升了模型在新环境中的适应能力。该方法在仅需10个样本的情况下就能达到90%以上的定位准确率。

#### 4.2.4 卫星通信系统

在卫星通信领域,深度学习主要应用于多波束卫星通信、轨道角动量波束形成等方面。2013年Zaharis等<sup>[66]</sup>针对卫星通信中的自适应波束形成问题,提出了基于MADIWO优化的RBFNN结构。该方法在旁瓣电平控制和零点放置方面表现优异,在存在多个干扰源的情况下仍能保持-30 dB以下的旁瓣电平。

2018年Di等<sup>[73]</sup>提出了一种基于拉格朗日规划的改进FFNN结构,特别适合卫星通信中的实时波束控制。该方法通过引入辅助变量神经元和拉格朗日神经元,显著提升了优化效率,网络结构比传统方法简单30%。

从应用领域的整体发展趋势来看,深度学习在波束形成技术中的应用呈现出多样化和深入化的特点。在移动通信领域,研究重点主要集中在大规模MIMO和毫米波通信等新型技术的支持上。雷达信号处理领域则更注重实时性能和抗干扰能力的提升。声学信号处理方面主要关注多目标分离和空间音频处理。卫星通信领域则强调系统可靠性和能量效率的优化。这种多领域协同发展的态势,推动了深度学习在波束形成技术中的持续创新和进步。

展望未来,深度学习在波束形成各应用领域将继续深化发展。在移动通信领域,6G技术的发展将带来更多挑战和机遇,深度学习将在智能超表面、全息MIMO等新型技术中发挥重要作用。雷达系统将向认知雷达和智能感知方向发展,需要更智能的波束形成算法支持。声学处理将更多关注实时性和鲁棒性,特别是在复杂声学环境下的应用。卫星通信将向低轨密集星座方向发展,对波束形成技术提出更高要求。这些发展趋势将推动深度学习在波束形成技术中的持续创新,为未来智能通信系统提供更强大的技术支撑。

### 4.3 深度学习方法性能对比与分析

为了更直观地展示不同深度学习架构在波束形成应用中的性能表现,表2汇总了主要研究工作的关键技术特征以及优缺点。

表2 基于深度学习的波束形成方法性能对比

Table 2 Performance comparison of deep learning-based beamforming methods

网络类型	代表性工作	应用场景	技术特点	优势	局限性
CAWE-ACNN	Liu等 <sup>[24]</sup> 提出的注意力卷积神经网络[3通道输入+注意力机制+权重预测网络]	互质传感器阵列自适应波束成形( $M=3, N=5$ 配置)	(1)双重注意力机制 ①通道注意力单元 ②空间注意力单元 (2)三通道输入设计	(1)最优的SINR性能 (2)充分利用互质阵列特性 (3)强大的干扰抑制能力 (4)高计算效率	(1)需要复杂的标签生成过程 (2)训练数据要求高 (3)网络结构相对复杂

续表

网络类型	代表性工作	应用场景	技术特点	优势	局限性
两阶段 CNN	Liao 等 <sup>[25]</sup> 提出的基于 CNN 的鲁棒自适应波束形成方法	(1)两阶段网络结构 (2)第 1 阶段估计协方差矩阵 (3)要增强目标信噪比 (4)自适应波束形成方法	(1)雷达、声纳和语音处理等需要增强目标信噪比的场景 (2)第 1 阶段估计协方差矩阵 (3)第 2 阶段计算自适应权重 (4)预训练 + 微调的训练策略	(1)在有限快照情况下性能优越(仅需 4 个快照) (2)对增益/相位误差具有鲁棒性 (3)形成更深的零点抑制干扰(比其他方法深 15 dB) (4)端到端处理, 无需中间特征提取 (5)在 SINR 方面比理想估计器近似收缩法(Oracle approximating shrinkage, OAS) 增大时性能下降	(1)训练过程计算开销大 (2)在线运行时间略长于传统方法 (3)增益/相位误差增大时性能下降 (4)需要大量模拟数据进行训练
ADL-MVDR	Zhang 等 <sup>[64]</sup> 提出的 ADL-MVDR 波束形成方法	目标语音分离、语音增强、ASR 前端处理	(1)使用两个 GRU 网络替代传统 MVDR 中矩阵求逆 (2)解决了传统 MVDR 中矩阵求逆的数值不稳定问题 (3)在各项客观指标上优于传统 MVDR 和纯神经网络方法 (4)ASR 准确率大幅提升	(1)显著降低残余噪声同时保持目标语音无失真 (2)解决了传统 MVDR 中矩阵求逆的数值不稳定问题 (3)在各项客观指标上优于传统 MVDR 和纯神经网络方法 (4)ASR 准确率大幅提升	(1)需要多通道麦克风阵列输入 (2)训练复杂度较高 (3)依赖于前端滤波器估计器的准确性 (4)需要大量训练数据
CRBF 神经网络	Li 等 <sup>[67]</sup> 提出的基于 CRBF 的快速鲁棒自适应波束形成方法	雷达、声纳、无线通信和医疗处理等需要自适应波束形成	(1)使用 CRBF 神经网络建立协方差矩阵 (2)直接处理复数虚部之间的关联性 (3)直接分离实部和虚部 (4)基于 MVDR 算法生成训练数据	(1)避免了直接矩阵求逆操作, 大幅降低计算复杂度 (2)保留了复数数据实部和虚部 (3)与实值 RBF 相比, 输入神经元数量减少一半 (4)波束零陷方向精确, 与层神经元数量相当 (5)对于大规模阵列, 计算用场景重新训练	(1)需要预先生成大量的非线性映射 (2)训练过程计算数据, 无需分离实部 (3)与实值 RBF 相比, 输入开销大 (4)需要为特定应用函数

续表

网络类型	代表性工作	应用场景	技术特点	优势	局限性
WS-MLMS	Took 等 <sup>[26]</sup> 提出的 MIMO 系统、基于 CNN 权重共享思想的多通道 MO、多通道自适应滤波方法	大 规 模 MI- 享思想的多通道 MO、多通道 信号处理	(1) 从 CNN 中借鉴权重共享思想 (2) 所有输入通道共享同一组权重 (3) 在“通道”维度而非“时间”维度上最小化误差平方和 (4) 利用所有通道的误差进行权重更新	(1) 计算复杂度显著降低(从 $O(P^2L)$ 降至 $O(PL)$ ) (2) 条件数更小, 数值稳定性更好 (3) 对大特征值扩散更鲁棒 (4) 对高斯和超高斯噪声更鲁棒性 (5) 能有效处理高达 256×256 的大规模 MIMO 系统	(1) 建模能力可能受限于权重共享约束 (2) 不适用于通道特性差异显著的场景 (3) 在低条件数情况下与传统 MLMS 性能相近
MLP	MLP 与 Tang 等 <sup>[75]</sup> 提出的无线通信中的瑞利熵优化结合的混合架构	基 于 深 度 学 习 的 抗 干 扰 场 景 、 过 瑞 利 商 问 题 求 解 结 合 的 可 移 动 天 线 阵 列 干 扰 抑 制 方 法	(1) 问题分解为接收波束形成和天线位置优化两个子问题 (2) 接收波束形成通过 MLP 网络学习 (3) 天线位置优化通过 MLP 网络学习 (4) 无监督学习框架 (5) 引入物理约束的天线位置映射	(1) 接近最优的抗干扰性能 (2) 显著降低在线推理的计算复杂度 (3) 利用可移动天线提供额外的自由度 (4) 相比固定位置天线获得更高的 SINR (5) 对多干扰源环境具有良好的鲁棒性 (6) 计算效率随干扰源数量和天线数量增加优势更明显	(1) 离线训练计算开销大 (2) 性能依赖于训练数据的质量和覆盖范围 (3) 与优化方法相比仍存在小的性能差距 (4) 需要已知信号到达方向 (5) 仅考虑单用户场景
4层 FFNN	Mallioras 等 <sup>[22]</sup> 提出的深度前馈网络	16 元现实微带天线阵列自适应波束成形	(1) 4 个隐藏层 (2) Tanh + Sigmoid 激活 (3) Adam 优化器 (4) ReduceLRonPlateau 学习率调节	(1) 响应速度快 (2) 结构相对简单 (3) 并行处理能力强	(1) 零点放置精度不足 (2) 未达到 $<0.1^\circ$ 的要求 (3) SINR 损失 0.67 dB
4层 GRU-RNN	Kassir 等 <sup>[62]</sup> 提出的线阵列自适应最优架构	16 元线性天线阵列自适应波束成形	(1) 多场景适应性 (2) 门控循环单元 (3) Tanh 激活函数 (4) Adam 优化器 (5) 学习率 0.0001	(1) 最佳综合性能 (2) 多信号场景适应性强 (3) 响应速度比 NSB 快 240 倍 (4) 精度接近理论最优 (5) 可处理 3~11 个人射信号	(1) 随着信号数量增加 (2) RMSE 性能逐渐下降 (3) 需要大量训练数据
3层 RBFNN	Sallam 等 <sup>[65]</sup> 提出的相控阵天气雷达向基函数神经网络	径 向 基 函 数 神 经 网 络 [ $N(N-1), K, 128 \times 2N$ ]	(1) 3 层前馈结构 (2) 径向基函数激活 (3) 高斯核函数 (4) Wiener 解训练 (5) 离线训练策略	(1) 最高精度估计 (2) 强杂波抑制能力 (3) 优秀泛化性能 (4) 实时处理能力 (5) 对噪声鲁棒性强	(1) 需要大量离线训练 (2) 训练数据依赖性强 (3) 隐藏层节点数需优化

续表

网络类型	代表性工作	应用场景	技术特点	优势	局限性
双通道 CNN	Wu 等 <sup>[21]</sup> 提出的宽带成形网络 [实部通道 + 虚部通道]	自适应宽带波束成形(低快拍数场景)	(1) 双通道架构实部、虚部分离处理 (2) 卷积层 + BN 层 + FC 层 (3) MSE 损失函数 (4) 梯度下降优化 (5) 步长 Stride=2, padding=1	(1) 极低快拍数下优异性能 (2) 深度零点形成能力 (3) 强干扰抑制能力 (4) 接近理想 SINR 输出 (5) 保持实虚部原始关联	(1) 需要大量训练数据 (2) 训练时间较长 (3) 网络结构相对复杂
4层 GRU-NN	Kassir 等 <sup>[27]</sup> 提出的 16 元微带贴片天线阵列波束成形[3, 128, 128, 128, 32]最优架构	(3 个入射信号)	(1) 4 个隐藏层 (2) 每层 128 个神经元 (3) Tanh 激活函数 (4) Adam 优化器 (5) 学习率 0.0001 (6) 1 000 训练轮次	(1) 最佳训练精度 (2) 精度接近 NSB 算法 (3) 响应速度比 NSB 快 240 倍 (4) 适合实时应用 (5) 在变化环境中鲁棒	(1) 响应时间比 FF-NN 慢 4 倍 (2) 结构相对复杂 (3) 需要大量训练数据

(1) 网络架构性能对比分析。从网络架构复杂度来看, GRU-RNN 系列在多个研究中表现出最佳的综合性能。Kassir 等<sup>[27]</sup>提出的 4 层 GRU-RNN 架构在 16 元天线阵列应用中实现了最低的均方根误差 (Root mean square error, RMSE) 值 (0.049), 同时保持了接近理论最优的精度, 响应速度比传统 NSB 算法快 240 倍。这表明门控循环单元在处理波束形成的时序特性方面具有显著优势, 能够有效捕获信号间的时间依赖关系。CNN 系列在特定应用场景中展现出独特优势。Wu 等<sup>[21]</sup>提出的双通道 CNN 在低快拍数宽带波束成形中表现优异, 通过实部虚部分离处理的双通道架构, 在仅 500 个快拍的极端条件下仍能接近理想 SINR 输出。而 CAWE-ACNN 通过引入双重注意力机制, 在互质传感器阵列中实现了最优的 SINR 性能, 充分利用了互质阵列的大孔径和高自由度特性。

(2) 应用场景适应性分析。不同网络架构在应用场景上呈现明显的专业化特征。RBFNN 在相控阵天气雷达应用中表现突出, Sallam 等<sup>[65]</sup>的 3 层 RBFNN 通过 Wiener 解训练策略, 在 128 元天线阵列的复杂环境中实现了强杂波抑制能力和优秀的泛化性能。ADL-MVDR 则专门针对语音处理场景优化, 通过两个 GRU 网络替代传统 MVDR 中的矩阵求逆操作, 在目标语音分离任务中将 ASR 准确率提升约 20%。两阶段 CNN 和复值 RBF 在鲁棒性要求较高的场景中表现优异。两阶段 CNN 在有限快照情况下(仅需 4 个快照)仍能保持优越性能, 并对增益/相位误差具有强鲁棒性。复值 RBF 通过直接处理复数数据, 保留了实部和虚部之间的关联性, 避免了传统方法中的矩阵求逆操作。

(3) 计算效率与实时性分析。在计算效率方面, 不同架构呈现出明显的权衡特征。FFNN 具有最快的响应速度(<1 ms), 但在零点放置精度上存在不足, SINR 损失达到 0.67 dB。WS-MLMS 通过权重共享思想显著降低了计算复杂度, 从  $O(P^2L)$  降至  $O(PL)$ , 特别适合大规模 MIMO 系统应用。混合架构方法如 Tang 等<sup>[75]</sup>提出的 MLP 与瑞利商优化结合的方案, 通过问题分解策略在保持接近最优性能的同时显著降低了在线推理的计算复杂度, 在多干扰源环境下计算效率随系统规模增加优势更加明显。

(4) 技术发展趋势与挑战。从技术发展趋势来看, 注意力机制和多阶段处理正成为提升波束形成性能的重要手段。CAWE-ACNN 的双重注意力机制(通道注意力和空间注意力)能够自适应地关注对权重估计贡献最大的特征, 而两阶段 CNN 通过预训练 + 微调策略实现了端到端的优化。然而, 所有深

度学习方法都面临训练数据依赖性强和离线训练开销大的共同挑战。大多数方法需要大量的仿真数据进行训练,且性能很大程度上依赖于训练数据的质量和覆盖范围。此外,在实际部署中,泛化能力和环境适应性仍是需要重点关注的问题,特别是在信号环境发生显著变化时,网络性能可能出现明显下降。

综合来看,深度学习在波束形成领域展现出巨大潜力,但不同架构各有优劣,需要根据具体应用场景的性能要求、计算资源限制和实时性需求进行合理选择。

#### 4.4 深度学习方法的局限性与挑战

在前述4.1~4.3节中,本文系统回顾了CNN、RNN、LSTM、RBFNN与FFNN等基于深度学习的波束形成方法的代表性进展与应用场景,并梳理了其性能优势与实现路径。需要指出的是,尽管这些方法在若干基准与仿真条件下表现突出,但对于其适用边界、计算与时延开销、硬件部署可行性以及分布外泛化能力等关键问题的讨论仍不充分。为增强批判性分析,本节将从上述4个维度展开系统审视,明确指出不同方法在何种实际场景中可能失效。

##### 4.4.1 适用边界与应用约束

基于深度学习的波束形成方法在实际应用中存在明显的适用边界限制。训练数据规模依赖性构成了基本约束,文献[29]显示深度学习MIMO自适应波束形成需要高达110万个训练记录,而文献[73]的拉格朗日规划神经网络需要1 000次迭代才能达到收敛。当训练数据不足时,网络的泛化能力会显著下降。快照数量依赖性制约了方法的实用性。文献[79]显示,传统方法在快照数为400时输出SINR约为-13 dB,而CNN方法虽然表现较好,但仍需要500个训练样本才能达到理想性能。文献[25]表明,当快照数量低于4个时,CNN的SINR输出仍明显低于最优值。阵列几何约束同样构成重要限制。现有方法主要针对均匀线阵进行设计<sup>[69,71-72]</sup>,文献[69]显示,当单元间距从半波长变化到其他值时,训练好的网络性能会显著下降。当阵列几何发生变化时,需要重新训练网络。

##### 4.4.2 计算复杂度与实时性挑战

训练阶段计算成本不容忽视。文献[23]指出宽带波束形成权重生成网络(Broadband beamforming weight generation network, BWGN)的训练需要约1 h,文献[66]的MADIWO网络需要执行500次迭代才能完成训练,文献[74]指出基于神经网络的Capon波束形成器在学习阶段的计算复杂度为 $O(M^4)$ 。推理时延的架构相关性在实时应用中尤为重要。文献[62]的测试表明,FFNN架构的推理时延最低( $<1$  ms),LSTM-RNN和GRU-RNN的时延为2~4 ms,而CNN架构的时延最高,可超过5 ms。文献[79]显示,GPU实现的神经波束形成器处理5 000个输入需要0.047 1 s,但CPU实现时增加到0.129 6 s。计算复杂度权衡问题在资源受限环境中表现突出。文献[24]的CAWE-ACNN算法浮点运算(FLOPs)达到8.77 M,显著高于传统对角加载样本矩阵求逆(Diagonal loading sample matrix inversion, DLSMI)方法的1.43 M。这种计算复杂度的增加在边缘计算场景中可能限制实际应用。

##### 4.4.3 硬件部署与工程实现难题

复数数据处理复杂性是首要问题。文献[67]指出,传统神经网络无法直接处理复数数据,需要将复数的实部和虚部分离处理,这不仅增加了网络规模,还可能损失相关性信息。文献[79]显示,1个复数乘法相当于4个浮点运算,这种转换过程不可避免地增加了计算量。模型压缩与精度损失的矛盾难以解决。文献[23]显示,即使采用了优化技术,去除挤压和激励(Squeeze-and-excitation, SE)模块后的网络性能仍出现明显下降,SINR损失可达1~2 dB。当量化位数低于8 bit时,网络性能会出现明显下降<sup>[28]</sup>。系统集成挑战增加了工程实现难度。文献[29,75]指出,深度学习波束形成器需要与MIMO收发器深度集成,要求极低的延迟处理时间和精确的计算资源利用,现有硬件架构可能无法直接支持高效执行。

#### 4.4.4 泛化能力与鲁棒性不足

有限鲁棒性在实际部署中表现明显。文献[71]研究表明,当导向矢量失配角度超过5°时,性能显著下降。文献[25]的研究表明,当G/P误差超过0.05时,CNN方法的SINR性能开始明显劣化,平均损失达到5 dB以上。训练与测试环境的分布差异制约了方法的实用性。文献[79]显示,虽然CNN能估计近似最优权值,但输出SINR仍比最优值低约0.5 dB。文献[79]的测试结果表明,当DOA步长从1°增加到3°时,输出SINR从23.87 dB下降到17.48 dB,显示出对训练数据分布的强烈依赖性。对抗鲁棒性缺乏使得系统面临安全威胁。深度学习模型容易受到对抗性扰动影响,恶意干扰者可能通过精心设计的干扰信号使网络产生错误的波束指向,但目前针对波束形成应用的对抗鲁棒性研究仍处于起步阶段。

#### 4.4.5 标注质量与可解释性问题

标签生成的准确性问题限制了方法的可靠性。文献[73]使用差分进化算法生成训练标签,该算法需要复杂的约束条件来确保零陷深度和旁瓣电平满足要求。文献[24]的CAWE-ACNN算法需要通过复杂的干扰加噪声协方差矩阵重构算法来生成标签,这一过程存在误差积累的风险,数据预处理复杂性增加了系统实现难度。文献[79]需要对接收信号自相关矩阵进行预处理,提取上三角或下三角元素,并进行归一化处理,这种预处理过程可能影响数据的内在相关性。模型可解释性不足给系统维护带来挑战。深度学习模型的“黑盒”特性使得故障诊断和性能优化变得困难<sup>[29]</sup>,当系统出现异常时,很难判断具体原因,增加了系统维护的复杂性和成本。

#### 4.4.6 特定应用场景的局限性

网络结构选择敏感性影响系统性能稳定性。文献[73]表明,LPNN采用3层结构比4层BPNN性能更好,均方误差改善44.7%,但这种结构选择高度依赖于具体应用,缺乏通用的设计准则。频带适应性限制在宽带应用中尤为突出。文献[79]的研究主要针对特定频段(800~1100 MHz)进行设计,当频带特性发生变化时,需要重新训练网络,限制了在多频段应用中的通用性。信号环境约束构成重要限制。文献[71]的方法假设了固定的干扰信号数量(2个),文献[75]假设了固定数量的干扰源(3个),当实际信号环境与训练假设不符时,性能可能下降。

综上所述,尽管深度学习波束形成方法在理论性能方面表现出色,但在实际部署中仍面临训练数据依赖性强、计算资源需求高、硬件实现复杂且泛化能力有限等多重局限性。这些挑战需要在方法设计和系统实现中给予充分关注,以确保技术的成功转化和应用。

### 5 未来研究方向

基于上述对深度学习在波束形成领域的研究现状分析,未来的研究方向主要包括以下几个方面。

#### (1) 网络架构创新

现有研究表明,单一网络结构在处理复杂波束形成问题时存在局限性。如Tang等<sup>[75]</sup>的研究虽然在移动通信中取得了良好效果,但其网络结构仍需要进一步优化以提升泛化能力。未来的研究方向应着重探索新型混合架构,特别是将Transformer机制与现有CNN、RNN结构结合。例如,可以借鉴Zhang等<sup>[64]</sup>提出的全深度学习MVDR框架思路,将自注意力机制引入波束形成网络,提升对长程空间依赖关系的建模能力。同时,参考Famoriji等<sup>[63]</sup>的元学习框架,探索更灵活的网络结构自适应机制,以应对不同场景的需求。

#### (2) 实时处理优化

实时处理能力是波束形成系统的关键指标。Liu等<sup>[24]</sup>的研究虽然在计算效率上取得了显著提升,但在大规模MIMO系统中仍面临挑战。未来研究应重点关注网络压缩和加速技术,包括模型量化、知识蒸馏和神经网络架构搜索(Neural architecture search, NAS)等方向。特别是借鉴Li等<sup>[67]</sup>提出的复值神经网络思路,探索更高效的参数表示方法。同时,结合Liao等<sup>[25]</sup>的端到端处理框架,研究流水线并行

处理策略,进一步降低系统延迟。

### (3) 鲁棒性增强

环境适应性和抗干扰能力是波束形成系统面临的重要挑战。Kikuchi等<sup>[74]</sup>在处理雷达杂波问题时的研究表明,现有方法在复杂电磁环境下仍存在改进空间。未来研究应重点探索基于对抗学习的鲁棒性训练方法,以及不确定性建模技术。可以参考Wu等<sup>[79]</sup>的频域约束思路,设计多域联合优化策略,提升系统在各种干扰条件下的稳定性。同时,借鉴Papari等<sup>[71]</sup>的采样函数网络思想,研究更有效的信号特征提取方法。

### (4) 跨场景迁移学习

当前的深度学习方法往往针对特定应用场景进行优化,跨场景适应能力有限。如Kassir等<sup>[27]</sup>的对比研究显示,不同网络结构在不同应用场景下表现差异显著。未来研究应重点关注迁移学习和领域自适应技术,探索知识在不同波束形成任务间的迁移机制。可以借鉴Ramezanpour等<sup>[80]</sup>的时空特征提取框架,设计更通用的特征表示方法。同时,参考Zaharis等<sup>[66]</sup>的优化策略,研究面向多场景的自适应学习算法。

### (5) 理论基础深化

深度学习在波束形成中的理论基础仍需加强。虽然Took等<sup>[26]</sup>对权重共享机制进行了理论分析,但对网络结构设计的理论指导仍显不足。未来研究应加强对深度学习模型可解释性的探索,建立波束形成性能与网络结构间的理论联系。可以参考Che等<sup>[59]</sup>的李雅普诺夫稳定性分析方法,深入研究网络收敛性和优化机制。同时,借鉴Di等<sup>[73]</sup>的拉格朗日规划思想,探索结合物理先验知识的网络设计理论。

### (6) 新型应用拓展

随着6G通信、智能反射面等新技术的发展,深度学习在波束形成领域面临新的应用机遇。Xue等<sup>[23]</sup>在宽带波束形成中的创新表明,深度学习可以有效解决新型通信系统中的复杂问题。未来研究应积极探索在智能超表面、全息MIMO、轨道角动量通信等新领域的应用。可以借鉴Liu等<sup>[24]</sup>的稀疏感知思路,研究面向新型天线系统的智能波束形成方法。同时,参考Bodepudi等<sup>[76]</sup>的补丁级处理思想,探索更适合新应用场景的处理框架。

## 6 结束语

本文系统地综述了深度学习在波束形成领域的研究现状和发展趋势。从网络架构的角度,详细分析了CNN、RNN、LSTM、RBFNN和FFNN等不同类型神经网络在波束形成中的应用特点和技术创新。从应用领域来看,深入探讨了深度学习在移动通信、雷达信号处理、声学信号处理和卫星通信等方面的具体实践。研究表明,深度学习方法在提升波束形成性能方面具有显著优势。如Liu等<sup>[24]</sup>提出的注意力CNN结构在大规模MIMO系统中实现了显著的计算效率提升。Zhang等<sup>[64]</sup>设计的全深度学习MVDR框架有效解决了传统算法中的数值不稳定问题。Famoriji等<sup>[63]</sup>开发的元学习框架大大提升了模型的环境适应能力。这些创新成果为波束形成技术的发展提供了新的思路和方法。

然而,现有研究仍存在一些局限性。首先,网络结构的设计往往缺乏理论指导,难以保证最优性;其次,实时处理能力在大规模系统中仍面临挑战;另外,模型的鲁棒性和泛化能力有待进一步提升。这些问题为未来研究指明了方向。

展望未来,深度学习在波束形成领域的应用将向着网络架构创新、实时处理优化、鲁棒性增强、跨场景迁移学习、理论基础深化和新型应用拓展等方向发展。特别是即将到来的第6代无线网络、智能反射表面/可重构智能表面等新兴技术领域<sup>[81]</sup>,深度学习将发挥更重要的作用。随着理论研究的深入和技术的不断创新,深度学习必将为自适应波束形成技术的发展注入新的活力,推动通信系统向更智能、更高效的方向演进。

## 参考文献：

- [1] VAN VEEN B D, BUCKLEY K M. Beamforming: A versatile approach to spatial filtering[J]. *IEEE ASSP Magazine*, 1988, 5(2): 4-24.
- [2] 张小飞, 李建峰, 徐大专. 阵列信号处理及 MATLAB 实现[M]. 北京: 电子工业出版社, 2020.  
ZHANG Xiaofei, LI Jianfeng, XU Dazhuan. *Array signal processing and MATLAB implementation*[M]. Beijing: Publishing House of Electronics Industry, 2020.
- [3] HOYDIS J, TEN BRINK S, DEBBAH M. Massive MIMO in the UL/DL of cellular networks: How many antennas do we need[J]. *IEEE Journal on Selected Areas in Communications*, 2013, 31(2): 160-171.
- [4] MARZETT A, THOMAS L. Noncooperative cellular wireless with unlimited numbers of base station antennas[J]. *IEEE Transactions on Wireless Communications*, 2020, 9(11): 3590-3600.
- [5] BROOKNER E. Phased array radars-past, present and future[C]//Proceedings of RADAR. Edinburgh, UK:[s. n.], 2002: 104-113.
- [6] HOWELLS P. Intermediate frequency side lobe canceller: US Pat. No.3202990[P]. 1965.
- [7] WIDROW B, MANTEY P, GRIFFITHS L, et al. Adaptive antenna systems[J]. *Proceedings of the IEEE*, 1967, 55(12): 2143-2159.
- [8] CAPON J. High-resolution frequency-wavenumber spectrum analysis[J]. *Proceedings of the IEEE*, 1969, 57(8): 1408-1418.
- [9] FROST O L. An algorithm for linearly constrained adaptive array processing[J]. *Proceedings of the IEEE*, 1972, 60(8): 926-935.
- [10] REED I S, MALLETT J D, BRENNAN L E. Rapid convergence rate in adaptive arrays[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1974, AES-10(6): 853-863.
- [11] HUNG H, KAVEH M. Focussing matrices for coherent signal-subspace processing[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1988, 36(8): 1272-1281.
- [12] CARLSON B D. Covariance matrix estimation errors and diagonal loading in adaptive arrays[J]. *IEEE Transactions on Aerospace Electronic Systems*, 1988, 24(4): 397-401.
- [13] COMPTON R. Adaptive antennas: Concepts and performance[J]. *IEEE Transactions on Antennas and Propagation*, 1988, 36(5): 598-608.
- [14] BELL K L, EPHRAIM Y, VAN TREES H L. A Bayesian approach to robust adaptive beamforming[J]. *IEEE Transactions on Signal Processing*, 2002, 48(2): 386-398.
- [15] LI J, STOICA P, WANG Z. On robust capon beamforming and diagonal loading[J]. *IEEE Transactions on Signal Processing*, 2003, 51(7): 1702-1715.
- [16] GU Y, LESHEM A. Robust adaptive beamforming based on interference covariance matrix reconstruction and steering vector estimation[J]. *IEEE Transactions on Signal Processing*, 2012, 60(7): 3881-3885.
- [17] GOOCH R, SHYNK J. Wide-band adaptive array processing using pole-zero digital filters[J]. *IEEE Transactions on Antennas and Propagation*, 2003, 51(3): 355-367.
- [18] DUAN H, NG B P, SEE C M. A new broadband beamformer using IIR filters[J]. *IEEE Signal Processing Letters*, 2005, 12(11): 776-779.
- [19] SEYDNEJAD S R, EBRAHIMI R. Broadband beamforming using Laguerre filters[J]. *Signal Processing*, 2012, 92(4): 1093-1100.
- [20] BUCKLEY K. Broad-band beamforming and the generalized sidelobe canceller[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1986, 34(5): 1322-1323.
- [21] WU X, ZHANG S, MA X, et al. The adaptive wideband beamforming using convolutional neural network[C]//Proceedings of 2022 International Conference on Microwave and Millimeter Wave Technology (ICMMT). [S.l.]: IEEE, 2022: 1-3.
- [22] MALLIORAS I, ZAHARIS Z D, LAZARIDIS P I, et al. A novel realistic approach of adaptive beamforming based on deep neural networks[J]. *IEEE Transactions on Antennas and Propagation*, 2022, 70(10): 8833-8848.
- [23] XUE C, ZHU H, ZHANG S, et al. Broadband beamforming weight generation network based on convolutional neural network [J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 1-5.
- [24] LIU F, ZHOU W, QIN D, et al. CAWE-ACNN algorithm for coprime sensor array adaptive beamforming[J]. *Sensors*, 2024, 24(17): 5454.

- [25] LIAO Z, DUAN K, HE J, et al. Robust adaptive beamforming based on a convolutional neural network[J]. *Electronics*, 2023, 12(12): 2751.
- [26] TOOK C C, MANDIC D. Weight sharing for LMS algorithms: Convolutional neural networks inspired multichannel adaptive filtering[J]. *Digital Signal Processing*, 2022, 127: 103580.
- [27] KASSIR H A, ZAHARIS Z D, LAZARIDIS P I, et al. Antenna array beamforming based on deep learning neural network architectures[C]//Proceedings of 2022 3rd URSI Atlantic and Asia Pacific Radio Science Meeting (AT-AP-RASC). [S.l.]: IEEE, 2022: 1-4.
- [28] LIN T, ZHU Y. Beamforming design for large-scale antenna arrays using deep learning[J]. *IEEE Wireless Communications Letters*, 2019, 9(1): 103-107.
- [29] BANU V, HUSSEIN L, GROVER V, et al. Adaptive beamforming in MIMO systems using deep learning[C]//Proceedings of 2024 IEEE International Conference on Communication, Computing and Signal Processing (IICCCS). [S.l.]: IEEE, 2024: 1-6.
- [30] DU K L, LAI A K Y, CHENG K K M, et al. Neural methods for antenna array signal processing: A review[J]. *Signal Processing*, 2002, 82(4): 547-561.
- [31] RAWAT A, YADAV R N, SHRIVASTAVA S C. Neural network applications in smart antenna arrays: A review[J]. *AEUE-International Journal of Electronics and Communications*, 2012, 66(11): 903-912.
- [32] NAJI A A, JAMEL T M, KHAZAAL H F. Review of: Deep learning (DL) for beamforming array (BFA) antenna[C]// Proceedings of 2024 21st International Multi-Conference on Systems, Signals & Devices (SSD). [S.l.]: IEEE, 2024: 49-56.
- [33] MOSTEGHANEMI R, BENYAROU M, BENDIMERAD F T. A review of the state of the art of beamforming techniques and AI[C]//Proceedings of 2024 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC). [S.l.]: IEEE, 2024: 1-6.
- [34] 沈峰麟,叶中付,钱玉美.信号统计分析与处理[M].合肥:中国科技大学出版社,2001.  
SHEN Fenglin, YE Zhongfu, QIAN Yumei. Statistical analysis and processing of signals[M]. Hefei: University of Science and Technology of China Press, 2001.
- [35] MUTAPCIC A, KIM S J, BOYD S. Beamforming with uncertain weights[J]. *IEEE Signal Processing Letters*, 2007, 14(5): 348-351.
- [36] FELDMAN D D, GRIFFITHS L J. A projection approach for robust adaptive beamforming[J]. *IEEE Transactions on Signal Processing*, 1994, 42(4): 867-876.
- [37] MESTRE X, LAGUNAS M A. Finite sample size effect on minimum variance beamformers: Optimum diagonal loading factor for large arrays[J]. *IEEE Transactions on Signal Processing*, 2005, 54(1): 69-82.
- [38] BOROSON D M. Sample size considerations for adaptive arrays[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 4: 446-451.
- [39] GE S, FAN C, WANG J, et al. Robust adaptive beamforming based on sparse bayesian learning and covariance matrix reconstruction[J]. *IEEE Communications Letters*, 2022, 26(8): 1893-1897.
- [40] HE J, SHU T, DAKULAGI V, et al. Simultaneous interference localization and array calibration for robust adaptive beamforming with partly calibrated arrays[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(5): 2850-2863.
- [41] WANG Y, ZHU D, JIN G, et al. A robust digital beamforming on receive in elevation for airborne MINO SAR system[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-19.
- [42] YANG X, LI Y, LIU F, et al. Robust adaptive beamforming based on covariance matrix reconstruction with annular uncertainty set and vector space projection[J]. *IEEE Antennas and Wireless Propagation Letters*, 2020, 20(2): 130-134.
- [43] MOORE A H, HAFEZI S, VOS R R, et al. A compact noise covariance matrix model for MVDR beamforming[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2022, 30: 2049-2061.
- [44] 金伟,贾维敏,张峰干.鲁棒自适应波束形成及应用[M].北京:北京邮电大学出版社,2021.  
JIN Wei, JIA Weimin, Zhang Fenggan. Robust adaptive beamforming and its applications[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2021.
- [45] 田玉坤,易翔,李鹏程.功率倒置自适应抗干扰算法的性能分析与仿真[J].电子信息对抗技术,2016, 31(5): 66-70.  
TIAN Yukun, YI Xiang, LI Pengcheng. Performance and simulation of adaptive anti-jamming based on power inversion algorithm[J]. *Electronic Information Warfare Technology*, 2016, 31(5): 66-70.

- [46] 张小飞, 张胜男, 徐大专. 自适应对角线加载的波束形成算法[J]. 中国空间科学技术, 2007, 4(2): 66-70.  
ZHANG Xiaofei, ZHANG Shengnan, XU Dazhuan. Adaptive diagonal loading beamforming algorithm[J]. Chinese Space Science and Technology, 2007, 4(2): 66-70.
- [47] 廖桂生, 保铮, 张林让. 基于特征结构的自适应波束形成新算法[J]. 电子学报, 1998, 26(3): 23-26.  
LIAO Guisheng, BAO Zheng, ZHANG Linrang. A new eigenstructure-based algorithm for adaptive beamforming[J]. Acta Electronica Sinica, 1998, 26(3): 23-26.
- [48] YU J L, YEH C C. Generalized eigenspace-based beamformers[J]. IEEE Transactions on Signal Processing, 1995, 43(11): 2453-2461.
- [49] LEE C C, LEE J H. Eigenspace-based adaptive array beamforming with robust capabilities[J]. IEEE Transactions on Antennas and Propagation, 1997, 45(12): 45.
- [50] LORENZ R G, BOYD S P. Robust minimum variance beamforming[J]. IEEE Transactions on Signal Processing, 2005, 53(5): 1684-1696.
- [51] 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.
- [52] RAMEZANPOUR P, MOSAVI M R. DNN-based interference mitigation beamformer[J]. IET Radar, Sonar & Navigation, 2020, 14(11): 1788-1794.
- [53] ELMAN J L. Finding structure in time[J]. Cognitive Science, 1990, 14(2): 179-211.
- [54] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [55] LOWE D, BROOMHEAD D. Multivariable functional interpolation and adaptive networks[J]. Complex Systems, 1988, 2(3): 321-355.
- [56] YANG X, GU J, JIANG J, et al. A radial basis function neural network beamforming method with beam steering[C]// Proceedings of 2021 4th International Conference on Information Communication and Signal Processing (ICICSP). [S.I.]: IEEE, 2021: 152-156.
- [57] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [58] MALLIORAS I, ZAHARIS Z D, LAZARIDIS P I, et al. An adaptive beamforming approach applied to planar antenna arrays using neural networks[C]// Proceedings of 2022 IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom). [S.I.]: IEEE, 2022: 293-297.
- [59] CHE H, LI C, HE X, et al. A recurrent neural network for adaptive beamforming and array correction[J]. Neural Networks, 2016, 80: 110-117.
- [60] RAMEZANPOUR M R, MOSAVI M R. Two-stage beamforming for rejecting interferences using deep neural networks[J]. IEEE Systems Journal, 2020, 15(3): 4439-4447.
- [61] LIU F, SUN X, LIU R, et al. AWB-FCNN algorithm for mainlobe interference suppression[J]. IEEE Transactions on Green Communications and Networking, 2025, 9(1): 218-227.
- [62] KASSIR H A, ZAHARIS Z D, LAZARIDIS P I, et al. Comparative study of neural network architectures applied to antenna array beamforming[C]// Proceedings of 2022 IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom). [S.I.]: IEEE, 2022: 282-287.
- [63] FAMORIJI O J, SHONGWE T. Deep learning approach to source localization of electromagnetic waves in the presence of various sources and noise[J]. Symmetry, 2023, 15(8): 1534.
- [64] ZHANG Z, XU Y, YU M, et al. ADL-MVDR: All deep learning MVDR beamformer for target speech separation[C]// Proceedings of ICASSP 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). [S.I.]: IEEE, 2021: 6089-6093.
- [65] SALLAM T, ABDEL-RAHMAN A B, ALGHONIEMY M, et al. A neural-network-based beamformer for phased array weather radar[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(9): 5095-5104.
- [66] ZAHARIS Z D, SKEBERIS C, XENOS T D, et al. Design of a novel antenna array beamformer using neural networks trained by modified adaptive dispersion invasive weed optimization based data[J]. IEEE Transactions on Broadcasting, 2013, 59(3): 455-460.
- [67] LI Y, YANG X, LIU F. Fast and robust adaptive beamforming method based on complex-valued RBF neural network[J]. The Journal of Engineering, 2019, 2019(19): 5917-5921.
- [68] ZAHARIS Z D, YIOULTSIS T V, SKEBERIS C, et al. Implementation of antenna array beamforming by using a novel

- neural network structure[C]//Proceedings of 2016 International Conference on Telecommunications and Multimedia (TEMU). [S.I.]: IEEE, 2016: 1-5.
- [69] PEI B, HAN H, SHENG Y, et al. Research on smart antenna beamforming by generalized regression neural network[C]// Proceedings of 2013 IEEE International Conference on Signal Processing, Communication and Computing (ICSPCC 2013). [S. I.]: IEEE, 2013: 1-4.
- [70] SENTHILKUMAR K, PIRAPAHARAN K, HOOLE PRP, et al. Single perceptron model for smart beam forming in array antennas[J]. International Journal of Electrical & Computer Engineering, 2016, 6(5): 2300-2309.
- [71] PAPARI J, OSKOUEI H D, KESHAVARZ A. Robust adaptive beamforming algorithm based on sampling function neural network[C]//Proceedings of the 2nd International Conference on Control, Instrumentation and Automation. [S.I.]: IEEE, 2011: 1187-1192.
- [72] SALLOMI AH, AHMED S. Multi-layer feed forward neural network application in adaptive beamforming of smart antenna system[C]//Proceedings of 2016 Al-Sadeq International Conference on Multidisciplinary in IT and Communication Science and Applications (AIC-MITCSA). [S.I.]: IEEE, 2016: 1-6.
- [73] DI B, ZHAO H, ZHAO Z, et al. Lagrange programming neural network for constraint antenna array beamforming[C]// Proceedings of 2018 12th International Symposium on Antennas, Propagation and EM Theory (ISAPE). [S.I.]: IEEE, 2018: 1-4.
- [74] KIKUCHI H, YOSHIKAWA E, USHIO U, et al. Clutter reduction for phased-array weather radar using diagonal capon beamforming with neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(12): 2065-2069.
- [75] TANG X, JIANG Y, LIU J, et al. Deep learning-assisted jamming mitigation with movable antenna array[J]. IEEE Transactions on Vehicular Technology, 2025, 74(9): 14865-14870.
- [76] BODEPUDI S, MADHAVANUNNI A, PANICKER M R. Patch based transformation for minimum variance beamformer image approximation using delay and sum pipeline[EB/OL]. (2021-11-19), <https://arxiv.org/abs/2110.10220>.
- [77] HAMZA S A, AMIN M G. Sparse array capon beamformer design availing deep learning[EB/OL]. (2021-08-20). <https://arxiv.org/abs/2108.08962>.
- [78] XU Z, PAN Z, GUO D. Adaptive beamforming algorithm based on automatic deep neural network optimization for multiple noise signals[J]. Journal of Internet Technology, 2025, 26(6):743-753.
- [79] WU X, LUO J, LI G, et al. Fast wideband beamforming using convolutional neural network[J]. Remote Sensing, 2023, 15 (3):712.
- [80] RAMEZANPOUR P, REZAEI M J, MOSAVI M R. Deep-learning-based beamforming for rejecting interferences[J]. IET Signal Processing, 2020, 14(7): 467-473.
- [81] 虞湘宾, 钱盼盼, 蔡鸿飞. 面向6G无线通信的可移动天线技术研究综述[J]. 南京航空航天大学学报, 2024, 56(5): 773-783.  
YU Xiangbin, QIAN Panpan, CAI Hongfei. Overview of movable antenna for 6G wireless communication[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2024, 56(5): 773-783.

#### 作者简介:



许峰(1987-),男,博士研究生,研究方向:阵列信号处理、卫星通信、深度学习,E-mail: xuzhengjust@126.com。



潘子豪(1998-),男,博士研究生,研究方向:阵列信号处理。



王宁(2001-),男,硕士研究生,研究方向:波束成形、深度学习。



郭道省(1973-),通信作者,男,教授,博士,研究方向:卫星通信、阵列信号处理、通信抗干扰、空天地一体化网络、物理层安全、无人机通信等,E-mail: xyzg-fg@sina.com。