

DOI: 10.20189/j.cnki.CN/61-1527/E.202503006

基于残差多层感知机网络的嵌套阵天线波达方向估计

王军伟, 何 川*, 彭文深, 汤继超, 曹 菲
(火箭军工程大学, 陕西 西安 710025)

摘 要: 针对传统嵌套阵天线波达方向 (direction of arrival, DOA) 估计算法存在模型复杂、计算量大的问题, 提出了一种基于残差多层感知机 (residual multilayer perceptron, ResMLP) 的嵌套阵 DOA 估计算法。该算法首先以嵌套阵接收信号的协方差矩阵 $\mathbf{R}$ 作为输入, 利用协方差矩阵的对称共轭性质对数据进行去冗余和一维化处理, 并采用主成分分析 (principal component analysis, PCA) 法对数据进行降维和去噪; 然后, 将残差结构 (residual structure) 与多层感知机 (multilayer perceptron, MLP) 相结合构建 ResMLP 网络, 以应对过深网络带来的梯度爆炸、梯度消失与退化问题, 并采用权重衰减法和暂退法防止网络过拟合; 最后, 采用基于 Yogi 修正的 Adam 算法作为优化算法, 利用余弦调度器调整学习率, 最终得到优化后的 ResMLP 网络模型。分别在快拍数 $K=512$ 、信噪比 SNR 位于 $[-10, 10]$ 区间内以及 SNR=0 dB、 K 位于 $[1, 512]$ 区间内的 2 种工况下, 通过不同 DOA 估计算法计算各信源入射角度的估计值。结果表明: ResMLP 算法的估计精度均优于基于虚拟阵列 (virtual array, VA) 变换的 MUSIC、root-MUSIC 和 ESPRIT 传统算法, 且计算速度更快, 鲁棒性更好, 尤其是在低信噪比和低快照条件下 ResMLP 算法的 DOA 估计性能表现较优。

关键词: 嵌套阵; DOA 估计; 残差多层感知机; 主成分分析

中图分类号: TN911.7

文献标志码: A

文章编号: 2097-2741(2025)03-054-10

Residual Multilayer Perceptron Network-Based Estimation of Direction of Arrival of Nested Arrays

WANG Junwei, HE Chuan*, PENG Wenshen,
TANG Jichao, CAO Fei

(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: A direction of arrival (DOA) estimation algorithm for nested arrays based on residual multilayer perceptron (ResMLP) was proposed to address high model complexity and com-

收稿日期: 2024-12-09

修回日期: 2025-02-15

录用日期: 2025-04-16

基金项目: 国家自然科学基金 (62473376); 陕西省特支计划青年拔尖人才 (TZ0328)

第一作者: 王军伟 (2001—), 男, 硕士研究生, 主要从事雷达信号分析与处理研究。E-mail: 18713040600@163.com

***通信作者:** 何川 (1985—), 男, 教授, 主要从事引爆控制与雷达抗干扰技术研究。E-mail: hechuan8512@163.com

引用格式: 王军伟, 何川, 彭文深, 等. 基于残差多层感知机网络的嵌套阵天线波达方向估计[J]. 火箭军工程大学学报, 2025, 39 (3): 54-63. WANG Junwei, HE Chuan, PENG Wenshen, et al. Residual multilayer perceptron network-based estimation of direction of arrival of nested arrays [J]. Journal of Rocket Force University of Engineering, 2025, 39 (3): 54-63.

putational load of the traditional DOA estimation method. First, the covariance matrix of the received signal of the nested array was considered as the input, and the symmetric conjugate property of the covariance matrix was used to eliminate redundancy and reduce the data to one dimension. Principal component analysis (PCA) was used to denoise and reduce the data dimensionality. Subsequently, the residual structure and multilayer perceptron (MLP) were combined to construct the a ResMLP network to address the issues of gradient explosion, gradient vanishing and degradation caused by deep networks. The weight decay method and dropout were used to prevent network overfitting. Finally, the Adam algorithm based on Yogi correction, was used as the optimization algorithm, and a cosine scheduler was utilized to adjust the learning rate. Ultimately, an optimized ResMLP network model was obtained. Under the two working conditions of the number of snapshots $K=512$ and the signal to noise ratio (SNR) in the range of $[-10, 10]$ and $\text{SNR}=0$ dB and K in the range of $[1, 512]$, the estimated value of the incident angle of each source was calculated using different DOA estimation algorithms. The results show that the ResMLP algorithm achieves higher estimation accuracy than traditional virtual array (VA) transform-based algorithms, such as MUSIC, root-MUSIC and ESPRIT, and offering faster computation speed and enhanced robustness. Especially under low SNR and snapshot conditions, the ResMLP algorithm exhibits superior DOA estimation performance.

KEYWORDS: nested array; direction of arrival estimation; residual multilayer perceptron; principal component analysis

雷达侦察与对抗是决定现代战争胜负的重要因素。现代战场信源数量众多, 情况复杂多变, 严重制约了传统阵列天线的发展。与传统阵列天线相比, 在相同阵元数条件下, 嵌套阵天线具有更高的估计精度和更多的可同时测量信源数, 且阵元间互耦效应更弱^[1], 这使得其在显著提升波达方向 (direction of arrival, DOA) 估计^[2]性能的同时, 能够实现雷达天线的轻量化设计, 从而减少成本。

嵌套阵是稀疏阵列的一种, 它将2个或多个子阵列以特定方式嵌套在一起以增加阵列的自由度 (degrees of freedom, DOF), 可通过虚拟阵列变换^[1]构造出数目远大于实际阵元数的虚拟阵元, 从而实现更好的DOA估计性能。Schmidt^[3]提出的MUSIC算法通过子空间分解和谱搜索的方法大大提高了DOA估计的精度, 是DOA估计领域的经典算法。Rao等^[4]在MUSIC算法的基础上提出了root-MUSIC算法, 用多项式求根替代了谱搜索, 提高了估计精度。白婷婷^[5]提出了基于MUSIC的低复杂度DOA估计算法, 通过比幅法和空间谱函数重构降低了算法的复杂度。Roy等^[6]提出了ESPRIT算法, 利用子空间的旋转不变性估计信号参数, 在保证一定估计精度的同时, 进一步降低了计算复杂度。以上算法均为针对均匀线阵 (uni-

form linear array, ULA) 提出的DOA估计方法, 无法直接应用于嵌套阵, 需要先进行虚拟阵列变换, 将嵌套阵转化为虚拟均匀线阵后再进行运算, 算法模型复杂、计算量大, 进一步限制了算法精度和计算速度的提高。

深度学习^[7-8]具备强大的特征学习能力, 能够适应多种复杂环境。葛晓凯等^[9]尝试将深度学习方法与压缩感知相结合进行相干源DOA估计, 可用于任意阵列结构, 在降低时间复杂度和提高预测准确度等方面表现较好。然而, 深度学习中网络深度会对模型产生显著影响, 过浅网络会使网络欠拟合, 无法充分学习数据间的内在联系; 过深网络会使网络过拟合^[10-11], 使模型的泛化能力减弱。同时, 由于梯度反向传播中的连乘效应, 导致过深网络的权重更新不稳定, 可能会导致梯度消失或梯度爆炸问题^[12]。He等^[13]通过实验表明, 即使解决了过拟合、梯度消失和梯度爆炸的问题, 过深网络依旧会出现退化现象, 其提出的ResNet网络通过使用快捷连接 (shortcut connections) 构建残差块, 可以有效解决过深网络带来的过拟合、梯度消失、梯度爆炸与退化问题, 证明了残差结构 (residual structure) 的有效性。ResNet作为卷积神经网络 (convolutional neural networks, CNN)^[14]的一种, 适用于处理图像信息

与具有局部相关性的非图像信息，而嵌套阵 DOA 估计的输入数据具有全局相关性，因此更适合使用以全连接层为核心的多层感知机（multilayer perceptron, MLP）进行处理。

针对上述问题，本文将残差结构与多层感知机相结合，提出了一种基于残差多层感知机（residual multilayer perceptron, ResMLP）^[15] 的嵌套阵 DOA 估计算法。该方法利用主成分分析（principal component analysis, PCA）^[16-17] 法来对数据进行预处理，采用权重衰减法（weight decay）^[18]、暂退法（dropout）^[19] 防止所构建的 ResMLP 网络出现过拟合，并采用 Adam 算法^[20] 对网络进行优化。针对 Adam 算法在一定条件下出现无法收敛的问题，采用 Yogi 算法^[21] 对其进行修正，并利用余弦调度器对学习率进行调整。最后，通过实验对比了本文所提方法与基于虚拟阵列变换的 MUSIC、root-MUSIC、ESPRIT 传统算法在 DOA 估计精度、计算速度和鲁棒性等方面的性能表现，同时还进一步分析了快拍数和信噪比参数对算法 DOA 估计性能的影响。

1 信号模型

1.1 基本模型

假设某嵌套阵共计有 M 个阵元，有 N 个信号源入射到该阵列上，且接收信号为远场窄带信号，则当第 i 个信号入射到第 l 个阵元上时，该阵元接收到的信号可表示为

$$x_l(t) = \sum_{i=1}^N g_{li} s_i(t) e^{-j\omega_0 \tau_{li}} + n_l(t) \quad l = 1, 2, \dots, M \quad (1)$$

式中： t 为时刻； j 为虚数单位； ω_0 为接收信号的角频率； g_{li} 为第 l 个阵元对于第 i 个信号的增益值； τ_{li} 为第 i 个信号到达第 l 个阵元时相对于参考阵元的时延值； $s_i(t)$ 为 t 时刻的第 i 个入射信号； $n_l(t)$ 为第 l 个阵元在 t 时刻接收到的噪声。假设在理想条件下，阵列中各阵元间具有各向同性且忽略互耦、通道不一致等因素的影响，则增益 g_{li} 可以省略，即 $g_{li} = 1$ 。此时， M 个阵元在 t 时刻接收到的信号可表示为

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_M(t) \end{bmatrix} = \begin{bmatrix} e^{-j\omega_0 \tau_{11}} & e^{-j\omega_0 \tau_{12}} & \dots & e^{-j\omega_0 \tau_{1N}} \\ e^{-j\omega_0 \tau_{21}} & e^{-j\omega_0 \tau_{22}} & \dots & e^{-j\omega_0 \tau_{2N}} \\ \vdots & \vdots & \ddots & \vdots \\ e^{-j\omega_0 \tau_{M1}} & e^{-j\omega_0 \tau_{M2}} & \dots & e^{-j\omega_0 \tau_{MN}} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_N(t) \end{bmatrix} +$$

$$\begin{bmatrix} n_1(t) \\ n_2(t) \\ \vdots \\ n_M(t) \end{bmatrix} \quad (2)$$

式 (2) 的矢量形式为

$$\mathbf{X} = \mathbf{A}\mathbf{S} + \mathbf{N} \quad (3)$$

式中： $\mathbf{X}$ 为阵列接收信号； $\mathbf{A}$ 为阵列的导向矢量阵； $\mathbf{S}$ 为信号源发出的信号； $\mathbf{N}$ 为各阵元接收到的噪声。

在 DOA 估计中， $\mathbf{X}$ 的协方差矩阵 $\mathbf{R}$ 是用于求解的关键参数，在实际工程应用中，通常使用采样协方差矩阵 $\hat{\mathbf{R}}$ 来计算，即

$$\hat{\mathbf{R}} = \frac{1}{K} \sum_{k=1}^K \mathbf{X} \mathbf{X}^H \quad (4)$$

式中： K 表示数据的快拍数。

1.2 嵌套阵

嵌套阵理论^[22] 在 2010 年由 Pal 等提出，主要包括二级嵌套阵和多级嵌套阵。二级嵌套阵是多级嵌套阵的基础，是最典型的嵌套阵结构，其研究结果对于多级嵌套阵具有一定的适用性，因此本文以二级嵌套阵为研究对象。二级嵌套阵由两个子阵组成，两个子阵均为均匀线阵，通过合理设置子阵的阵元数，可使阵列的自由度最大。

设一级子阵阵元数为 M_1 ，二级子阵阵元数为 M_2 ，一级子阵阵元间距为 $d = \lambda/2$ ，则有二级子阵阵元间距为 $(M_1 + 1)d$ ，即 $\lambda(M_1 + 1)/2$ 。其中， λ 表示接收信号的波长，阵列结构如图 1 所示。




图 1 二级嵌套阵列结构

Fig. 1 Structure of second-level nested array

若阵元总数 M 为奇数，则当一级子阵阵元数为 $(M - 1)/2$ 且二级子阵阵元数为 $(M + 1)/2$ 时，阵列自由度最大；若阵元总数 M 为偶数，则当一级和二级子阵阵元数均为 $M/2$ 时，阵列自由度最大^[23]。

此时，该嵌套阵的阵列孔径为

$$A = [M_2(M_1 + 1) - 1] \cdot d \quad (5)$$

阵列自由度为

$$d_{\text{DOF}} = 2M_2(M_1 + 1) - 1 \quad (6)$$

2 ResMLP 网络

2.1 数据预处理

2.1.1 一维化转换

由式 (4) 可得, 接收数据的协方差矩阵 $\mathbf{R}$ 是一个 Hermite 阵^[1], 其元素关于对角线对称共轭, 因此其上半部分的元素 (含对角线) 即包含了协方差矩阵 $\mathbf{R}$ 中的全部信息。因而可以将矩阵 $\mathbf{R}$ 的上半部分转化成一维数据, 并将实部与虚部分离, 然后将生成的一维数据作为 ResMLP 网络的输入。假设阵元个数为 M , 则输入数据维数为

$$P = M + (M - 1) + \dots + 1 = \frac{M(M + 1)}{2} \quad (7)$$

2.1.2 PCA 降维和去噪

由式 (7) 可得, 当阵元个数较多时, 数据维数也较大, 不利于神经网络的训练。因此, 本文采用 PCA 法对原始数据进行降维和去噪处理, 它可以在尽可能多地保留原有数据信息的前提下, 将高维数据转化为低维数据。

PCA 法能够将原有的指标转化为数量较少的主成分, 其中每种主成分都是原指标的线性组合, 同时每种主成分之间互不相关。在 DOA 估计问题中, 协方差矩阵 $\mathbf{R}$ 中各元素之间具有一定的相互关联性, 即存在一定的信息冗余, 使用 PCA 对数据进行降维可以有效简化数据, 突出数据之间的主要矛盾, 便于神经网络的训练。

2.1.3 标准化和最大最小值归一化

对数据进行标准化处理, 使数据满足标准正态分布, 以便于神经网络进行学习, 其表达式为

$$X' = \frac{X_s - \mu}{\sigma} \quad (8)$$

式中: X_s 为原始数据; μ 为原始数据的均值; σ 为原始数据的方差; X' 为标准化后的数据。

对标准化后的数据进行最大最小值归一化 (min-max normalization)^[24] 处理, 将输入数据缩放到 $[0, 1]$ 区间内, 以消除不同特征之间的尺度差异, 其表达式为

$$X'' = \frac{X' - X'_{\min}}{X'_{\max} - X'_{\min}} \quad (9)$$

式中: $X'_{\min}$ 为数据最小值; $X'_{\max}$ 为数据最大值; X'' 为归一化后的数据。

2.2 残差块结构

He 等^[13] 在 ResNet 网络中提出了残差学习的概念, 通过使用快捷连接允许网络中的信号绕过一

些层进行直接传递, 从而解决了深度神经网络训练中的梯度消失、梯度爆炸和退化问题。这种设计使得网络能够训练更深的层数, 同时保持了训练的稳定性, 提高了模型的性能和准确性。

ResNet 网络属于一种卷积神经网络, 主要用于处理图像数据。通过使用快捷连接, 使网络中的信号绕过部分全连接层后直接传递给下一个残差块, 使每个残差块传递给下一层的输入变为

$$H(x) = F(x) + x \quad (10)$$

式中: x 为 ResNet 网络的输入; $H(x)$ 为残差网络的总输出; $F(\cdot)$ 为残差函数, 是网络实际要学习的部分。由此可得 ResNet 网络非线性层的映射, 即拟合残差为

$$F(x) = H(x) - x \quad (11)$$

当网络深度过深时, 希望深层部分的非线性层能够实现恒等映射, 即该层的输入等于输出, 这就要求非线性层的输出函数满足 $F(x) = x$ 。然而, 在传统的神经网络中, 这是难以实现的, 但是在 ResNet 网络中, 由式 (11) 可知, 如需实现 $H(x) = x$, 只需要该层满足 $F(x) = 0$ 。对于非线性层而言, 输出拟合为 0 比拟合为 x 要容易得多, 可以通过快捷连接来实现, 它可以跳过一个或多个层将残差块的输入直接添加到残差块的输出中去。快捷连接不会增加额外参数, 不会使算法的计算复杂度提高, 但却能有效解决网络过深带来的梯度爆炸、梯度消失与退化问题。然而, He 等提出的 ResNet 网络不适用于处理具有全局相关性的非图像信息, 因此本文将残差结构与多层感知机相结合, 构建 ResMLP 网络来对嵌套阵 DOA 进行估计。在该网络中, 残差块结构的核心为全连接层、Leaky ReLU 激活函数、Dropout 层和一个快捷连接, 残差块结构如图 2 所示。

2.3 网络优化算法

本文采用 Leaky ReLU^[25] 作为网络的激活函数, 它是 ReLU 的改进型。ReLU 在过深网络中可能导致“神经元死亡”的问题, 即某些神经元的输入始终小于等于 0, 导致梯度为 0, 使这些神经元无法更新。为了解决这一问题, Leaky ReLU 函数在负值区域引入了一个小的斜率, 使得负值区域的输出不再始终为 0, 从而避免了“神经元死亡”现象的发生, 还有助于保持梯度的流动, 增强模型的表达能力和泛化能力。ReLU 和 Leaky ReLU 激活函数的表达式分别为




图 2 残差块结构

Fig. 2 Structure of residual block

$$y_{\text{ReLU}} = \max(0, x) \quad (12)$$

$$y_{\text{Leak ReLU}} = \max(-\alpha x, x) \quad (13)$$

同时, 本文还利用权重衰减法来缓解深度学习在训练中易出现过拟合的问题。权重衰减法是通过在损失函数中加入惩罚项来抑制权重过大, 其损失函数可表示为

$$L = L_0 + \alpha_{l2} \sum_i \omega_i^2 \quad (14)$$

式中: L 为损失函数; L_0 为原始损失函数; α_{l2} 为权重衰减参数; $\sum_i \omega_i^2$ 为权重向量二范数的平方。

权重的更新公式可表示为

$$\omega'_i = \omega_i - \eta \left(\frac{\partial L_0}{\partial \omega_i} + 2\alpha_{l2} \omega_i \right) \quad (15)$$

式中: ω'_i 为更新后的权重; η 为学习率。

在深度神经网络中, 如果 2 个神经元总是同时被激活或同时不被激活, 则它们之间可能会存在过度依赖, 导致模型在训练数据集上学得过于精细, 从而产生过拟合现象。针对这一问题, 本文使用暂退法, 通过随机丢弃神经元, 有效减少了神经元间共适应现象, 使每个神经元在学习时更加注重从不同神经元组合中提取特征, 从而提升了模型的泛化能力。其本质在于构建一个模型平均机制, 在每次训练迭代中随机选择不同的神经子网络, 最终得到的模型可视为多个子模型的集成, 从而增强了模型的鲁棒性。同时, 暂退法通过隐式降低模型的有效容量, 减少了过拟合的风险, 使模型不过度依赖训练数据中的噪声和细节。其中, 第一层 Dropout 层中暂退率设为 $d_1 = 0.2$, 各残差块中的 Dropout 层中暂退率设为 $d_2 = 0.5$ 。

另外, 针对 Adam 算法在梯度的二阶短估计值发生爆炸时无法收敛的问题, 本文采用带有 Yogi 更新的 Adam 算法作为优化算法。Yogi 在更新梯

度平方和时, 引入了评估梯度平方与历史估计值差异的符号函数, 从而避免了 Adam 算法中梯度平方和过快增长导致的学习率不稳定。同时, 采用余弦调度器来对学习率进行动态调整。余弦调度器在训练初期, 学习率较高, 能使模型更快地探索最优解。随着训练的进行, 学习率逐渐下降, 使模型能稳定收敛。相比于线性衰减, 余弦曲线能更平稳地调整学习率, 从而避免梯度更新过快或过慢, 学习率更新公式为

$$\eta_e = \begin{cases} \eta_E + \frac{\eta_0 - \eta_E}{2} \left(1 + \cos\left(\pi \frac{e}{E}\right) \right), & e < E \\ \eta_E, & e \geq E \end{cases} \quad (16)$$

式中: e 为当前迭代轮次; E 为学习率达到最低时的迭代轮次; η_e 为第 e 轮的学习率; η_0 为初始学习率; η_E 为最终学习率。学习率变化曲线如图 3 所示, ResMLP 整体网络结构如图 4 所示。




图 3 余弦调度器算法学习率变化曲线

Fig. 3 Curve of learning rate of the cosine scheduler algorithm




图 4 ResMLP 整体网络结构

Fig. 4 Overall network structure of ResMLP

3 实验仿真与分析

3.1 实验环境与参数设置

本文实验环境均基于 Python 3.9, 设备使用 4090D 显卡、i9-14900KS 处理器、64 GB 内存。实验中设置二级嵌套阵的总阵元数为 10, 当一级和二级子阵阵元数相等时, 阵列自由度最大^[23], 因此设一级子阵与二级子阵阵元数均为 5。存在 3 个远场窄带信源, 不考虑阵元间的互耦效应影响。仿真样本由蒙特卡洛算法^[26]生成, 共 10 000 个, 其中, 包括 7 000 个训练集样本, 1 500 个验证集样本和 1 500 个测试集样本, 噪声类型采用高斯白噪声。ResMLP 网络的参数设置如表 1 所示。

表 1 ResMLP 网络的参数设置

Table 1 Parameter settings of ResMLP network

参数	参数解释	设定值
n_{epochs}	迭代次数	800
n_{clock}	残差块数量	5
α_{Leaky}	Leaky ReLU 参数	0.01
$\alpha_{1,2}$	权重衰减参数	3
d_1	暂退法中第一层的暂退率	0.2
d_2	暂退法中中间层的暂退率	0.5
β_1	Yogi 算法参数	0.9
β_2	Yogi 算法参数	0.999
η_0	初始学习率	0.001
η_{E}	最小学习率	0.000 1

其中, 本实验主要采用均方根误差 $\varepsilon_{\text{RMSE}}$ 、平均绝对误差 ε_{MAE} 和决定系数 R^2 作为衡量算法性能的指标, 其计算公式如下。

$$\varepsilon_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$\varepsilon_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (19)$$

式中: n 为样本个数; y_i 为第 i 个样本的真实值; $\hat{y}_i$ 为第 i 个样本的预测值; $\bar{y}$ 为 n 个样本的平均值。

3.2 ResMLP 网络的训练表现

设信噪比 SNR 为 0 dB, 快拍数 K 为 512, 入射信号的角度设定为 $-80^\circ \leq \theta \leq 80^\circ$, 则 ResMLP 网络模型的整体性能指标如表 2 所示, 其预测效果


如图 5 所示。

表 2 ResMLP 网络模型性能指标


Table 2 Performance index of ResMLP model

参数	数值
$\varepsilon_{\text{RMSE}}$	1.388 6°
ε_{MAE}	1.053 3°
R^2	0.999 1
t_s	1.1×10^{-5} s


注: t_s 为模型预测耗时。



(a) 预测值与真实值的关系



(b) ε_{MAE} 值随角度分布情况



(c) $\varepsilon_{\text{RMSE}}$ 值随角度分布情况

图 5 ResMLP 网络模型预测效果

Fig. 5 Prediction performance of ResMLP network model

在图 5 (a) 中, 每个蓝点代表一个样本, 横坐标表示其真实值, 纵坐标表示其预测值。理想状态下, 样本点的真实值应当等于预测值, 样本点应位于参考线 $y=x$ 上。从图 5 (a) 可以看出, 样本点基本集中于参考线 $y=x$ 附近, 表明模型的预测效果较好。同时, 参考线上方的样本点数量整体上与参考线下方的样本点数量相同, 并且在不同角度区间内的样本点与参考线之间的距离也

大致相等,表明模型不存在预测结果整体偏大或整体偏小的情况。

图 5 (b) 利用箱线图给出了本文算法预测结果的 ε_{MAE} 在不同角度区间内的分布情况,从图中可以看出,不同角度区间内的 ε_{MAE} 值均较小,且分布较为均匀,部分区间内的 ε_{MAE} 中位数小于 1; 在 $[-40^\circ, -10^\circ)$, $[0^\circ, 10^\circ)$ 与 $[40^\circ, 60^\circ)$ 区间内 ResMLP 算法的 ε_{MAE} 值相对较高。与传统 DOA 估计算法中边缘角度 DOA 估计效果较差的特点不同,本文算法在边缘角度处的 DOA 估计误差相对较小。

图 5 (c) 利用柱状图给出了本文算法预测结果的 $\varepsilon_{\text{RMSE}}$ 在不同角度区间内的分布情况,从图中可以看出,不同角度区间内的 $\varepsilon_{\text{RMSE}}$ 值均较小,且分布较为均匀,各区间内的 $\varepsilon_{\text{RMSE}}$ 均位于 $[1.25, 1.80]$ 区间内; 在 $[-40^\circ, -10^\circ)$, $[0^\circ, 20^\circ)$ 与 $[40^\circ, 60^\circ)$ 区间内 ResMLP 算法的 $\varepsilon_{\text{RMSE}}$ 值相对较高,边缘角度处的 DOA 估计误差相对较小。

3.3 信噪比对估计性能的影响

本节以经典算法中的 MUSIC 算法、root-

MUSIC 算法、ESPRIT 算法作为对照进行实验。然而上述经典算法只适用于均匀线阵,无法直接用于嵌套阵 DOA 估计^[1],因此在对照实验中先进行虚拟阵列变换,再分别使用 MUSIC 算法、root-MUSIC 算法、ESPRIT 算法进行 DOA 估计,分别记为 VA+MUSIC、VA+root-MUSIC、VA+ESPRIT。本实验中所使用的样本为 3.1 节中 1 500 个测试集样本,仿真环境与 3.1 节相同。

在快拍数 K 为 512 的条件下,ResMLP 与 VA+MUSIC、VA+root-MUSIC、VA+ESPRIT 在不同信噪比条件下的 DOA 估计性能表现如图 6 所示。其中,在图 6 (d) 中由于 VA+root-MUSIC 算法计算时间在本文设置的实验条件下均大于 24 ms,明显慢于其他 3 种算法,因此不在图中显示,下文中国 6 (d) 同理。

从图 6 (a)、(b) 中可以看出,本文提出的 ResMLP 算法的 $\varepsilon_{\text{RMSE}}$ 明显低于 VA+MUSIC、VA+root-MUSIC、VA+ESPRIT 传统算法; 当 $\text{SNR} < -2$ dB 时,ResMLP 的 ε_{MAE} 明显低于其他 3 种传统算法; 当信噪比较高时,其 ε_{MAE} 略高于传




图 6 不同算法的 DOA 估计性能随信噪比的变化情况

Fig. 6 Variation of DOA estimation performance of different algorithms with the signal-to-noise ratios

统算法。综合 $\varepsilon_{\text{RMSE}}$ 和 ε_{MAE} 两项指标可以得出, 当信噪比 SNR 处于 $[-10, 10]$ 区间内时, ResMLP 的运算精度优于传统算法。同时, 从图 6 (c) 中可以看出, ResMLP 算法的 R^2 接近于 1, 其拟合程度均高于其他 3 种传统算法。

从图 6 (d) 中可以看出, ResMLP 算法在 $-10 \text{ dB} \leq \text{SNR} \leq 10 \text{ dB}$ 时的运算所需时间均小于 0.1 ms , 运算速度远超 VA+MUSIC 算法和 VA+root-MUSIC 算法, 同时略快于 VA+ESPRIT 算法。另外, 本文算法在不同 SNR 处 t_s 的方差为 8.669×10^{-7} , 远小于 VA+MUSIC、VA+root-MUSIC、VA+ESPRIT 传统算法, 因而可以认为在 $-10 \text{ dB} \leq \text{SNR} \leq 10 \text{ dB}$ 时该算法的运算所需时间对 SNR 的变化不敏感, t_s 变化幅度较小。这是因为在既定的真实环境背景下, ResMLP 算法能够借助离线训练的方式, 在实际应用场景中直接部署模型, 从而显著提升计算效率。同时, ResMLP 网络利用暂退法降低算法复杂度, 并充分利用了计算机的并行计算能力提高计算效率。然而, 针对嵌套阵的传统 DOA 估计算法, 如 VA+MUSIC、

VA+root-MUSIC、VA+ESPRIT 等, 通常需要进行特征值分解、谱峰搜索以及多项式求根等复杂的数学运算, 这些运算不仅计算量大, 而且对数据的质量和条件要求较高。因此, 在既定的复杂电磁环境中, ResMLP 算法在嵌套阵 DOA 估计问题上, 其计算速度均优于上述 2 种传统算法。

综上所述, 当信噪比处于 $[-10, 10]$ 区间内时, ResMLP 的运算精度整体上优于其他 3 种传统算法, 且计算速度更快, 在信噪比较低时表现更优。虽然 ResMLP 的 ε_{MAE} 在高信噪比时略逊于传统算法, 但由于 $\varepsilon_{\text{RMSE}}$ 指标对于数据中的异常值更为敏感, 因此表明 ResMLP 的预测较为稳定, 异常值较少, 且考虑到其 R^2 接近于 1, 表明 ResMLP 在 $-10 \text{ dB} \leq \text{SNR} \leq 10 \text{ dB}$ 时具有较好的鲁棒性。

3.4 快拍数对估计性能的影响

本节实验的仿真环境与 3.1 节相同。在信噪比设定为 0 dB 的条件下, 本文算法与虚拟阵列变换后的 MUSIC 算法、root-MUSIC 算法、ESPRIT 算法在不同快拍数条件下的 DOA 估计性能表现如图 7 所示。




图 7 不同算法的 DOA 估计性能随快拍数的变化情况

Fig. 7 Variation of DOA estimation performance of different algorithms with the number of snapshots

从图 7 (a)、(b) 可以看出, 当快拍数处于 [1, 512] 区间内时, ResMLP 算法的 $\varepsilon_{\text{RMSE}}$ 均低于其他 3 种传统算法, 而 ResMLP 的 ε_{MAE} 与传统算法区别不大。从图 7 (c) 可以看出, 当 $K \leq 128$ 时, ResMLP 算法的 R^2 明显优于传统算法; 当 $K > 128$ 时, ResMLP 算法的 R^2 接近于 1, 略优于传统算法。

从图 7 (d) 中可以看出, ResMLP 算法的运算速度远快于 VA+MUSIC 和 VA+root-MUSIC 算法, 略快于 VA+ESPRIT 算法。本文算法的运算所需时间约为 0.01 ms, 在不同 SNR 处 t_s 的方差为 4.133×10^{-7} , 远小于 VA+MUSIC、VA+root-MUSIC、VA+ESPRIT, 因此可以认为在 $1 \leq K \leq 512$ 时为该算法运算所需时间 t_s 对 K 的变化不敏感, 变化幅度较小。

综上所述, 当快拍数处于 [1, 512] 区间内时, 本文算法的估计精度均优于其他 3 种传统算法, 且估计速度更快, 尤其在快拍数较小时表现更优, 在 $1 \leq K \leq 512$ 时同样具有较好的鲁棒性。

4 结论

本文提出一种基于 ResMLP 网络的嵌套阵 DOA 估计方法, 将残差结构与多层感知机相结合, 并采用权重衰减法等算法来对网络进行优化。在不同信噪比、不同快拍数条件下进行仿真模拟实验, 得出如下结论。

1) 在本文设定的实验条件下, 该算法的 DOA 估计精度和估计速度均优于基于虚拟阵列变换的 MUSIC、root-MUSIC 和 ESPRIT 3 种传统算法。

2) 在本文设定的实验条件下, 本文算法具有较好的鲁棒性, 受数据质量和外界干扰的影响较小, 在不同环境下具有较好的泛用性。

3) 相较于 3 种传统算法, 该算法在低信噪比、低快拍数的极端情况下优势更为明显, 说明该算法对极端环境具有较好的适应性。

本文为复杂电磁环境中多信源实时测向提供了新方法。然而, 该算法对先验数据的依赖性较强, 适用于既定的真实环境背景, 下一步可将该算法与强化学习相结合, 使其能够更加适应动态变化的复杂电磁环境。

参考文献

[1] 王永良, 陈辉, 彭应宁, 等. 空间谱估计理论与算法

[M]. 北京: 清华大学出版社, 2004: 26-371.

[2] LIU F L, LI X B, SU Z B, et al. Mc-music algorithm for fast DOA estimation[J]. Wireless Networks, 2025, 31(1): 659-667.

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

[4] RAO B D, HARI K V S. Performance analysis of root-MUSIC[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1989, 37(12): 1939-1949.

[5] 白婷婷. DOA 估计方法研究[D]. 成都: 电子科技大学, 2024: 17-35.

BAI T T. Research on DOA estimation method [D]. Chengdu: University of Electronic Science and Technology of China, 2024: 17-35.

[6] ROY R, KAILATH T. ESPRIT-estimation of signal parameters via rotational invariance techniques [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1989, 37(7): 984-995.

[7] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[8] 王洋洋, 曹菲. 基于广义回归神经网络插值的雷达引信回波模拟[J]. 火箭军工程大学学报, 2024, 38(5): 69-80.

WANG Y Y, CAO F. Rader fuse echo simulation based on generalized regression neural network interpolation[J]. Journal of Rocket Force University of Engineering, 2024, 38(5): 69-80.

[9] 葛晓凯, 胡显智, 戴旭初. 利用深度学习方法的相干源 DOA 估计[J]. 信号处理, 2019, 35(8): 1376-1384.

GE X K, HU X Z, DAI X C. DOA estimation for coherent sources using deep learning method[J]. Journal of Signal Processing, 2019, 35(8): 1376-1384.

[10] BEJANI M M, GHATEE M. A systematic review on overfitting control in shallow and deep neural networks[J]. Artificial Intelligence Review, 2021, 54(8): 6391-6438.

[11] ROTH B, LUZ DE ARAUJO P H, XIA Y X, et al. Specification overfitting in artificial intelligence[J]. Artificial Intelligence Review, 2024, 58(2): 35.

[12] LIU M, CHEN L M, DU X H, et al. Activated gradients for deep neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(4): 2156-2168.

[13] HE K M, ZHANG X Y, REN S P, et al. Deep

- residual learning for image recognition[EB/OL]. (2015-12-10)[2024-11-10]. <https://doi.org/10.48550/arXiv.1512.03385>.
- [14] 李邦杰, 武健, 张大巧, 等. 基于卷积神经网络的景象匹配区适配性筛选方法[J]. 火箭军工程大学学报, 2024, 38(3): 45-50, 59.
- LI B J, WU J, ZHANG D Q, et al. A CNN-based scene matching adaptability screening method[J]. Journal of Rocket Force University of Engineering, 2024, 38(3): 45-50, 59.
- [15] WANG Z S, WANG C F, LI X S, et al. MLP-net: multilayer perceptron fusion network for infrared small target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 63: 5601313.
- [16] RENWICK BEATTIE J, ESMONDE-WHITE F W L. Exploration of principal component analysis: deriving principal component analysis visually using spectra[J]. Applied Spectroscopy, 2021, 75(4): 361-375.
- [17] DORABIALA O, ARAVKIN A Y, KUTZ J N. Ensemble principal component analysis[J]. IEEE Access, 2024, 12: 6663-6671.
- [18] KOBAYASHI S, AKRAM Y, VON OSWALD J. Weight decay induces low-rank attention layers[EB/OL]. (2024-10-31)[2024-11-10]. <https://doi.org/10.48550/arXiv.2410.23819>.
- [19] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15: 1929-1958.
- [20] REYAD M, SARHAN A M, ARAFA M. A modified Adam algorithm for deep neural network optimization[J]. Neural Computing and Applications, 2023, 35(23): 17095-17112.
- [21] ZAHEER M, REDDI S, SACHAN D, et al. Adaptive methods for nonconvex optimization[C]// Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2018: 9815-9825.
- [22] PAL P, VAIDYANATHAN P P. Nested arrays: a novel approach to array processing with enhanced degrees of freedom[J]. IEEE Transactions on Signal Processing, 2010, 58(8): 4167-4181.
- [23] 牟仕林. 非均匀稀疏阵DOA估计研究[D]. 成都: 电子科技大学, 2020: 11-12.
- MU S L. Research on DOA estimation of non-uniform sparse arrays[D]. Chengdu: University of Electronic Science and Technology of China, 2020: 11-12.
- [24] HUANG L, QIN J, ZHOU Y, et al. Normalization techniques in training dNNs: methodology, analysis and application[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 10173-10196.
- [25] NAYEF B H, ABDULLAH S N H S, SULAIMAN R, et al. Optimized leaky ReLU for handwritten Arabic character recognition using convolution neural networks[J]. Multimedia Tools and Applications, 2022, 81(2): 2065-2094.
- [26] JONES G L, QIN Q. Markov chain Monte Carlo in practice[J]. Annual Review of Statistics and Its Application, 2022, 9: 557-578.

(编辑: 刘建民)