

DOI:10.19651/j.cnki.emt.2519820

# 基于轻量化级联神经网络的信号 DOA 估计\*

熊伟华 章 勇 张雪梅 李良尧

(东华理工大学电子与电气工程学院(智能制造学院)南昌 330013)

**摘要:** 针对现有基于深度学习的 DOA 估计算法存在参数量大、依赖易受噪声干扰的协方差矩阵输入,难以部署于资源受限的边缘设备的问题。本文提出一种轻量化卷积分类-回归神经网络 DOA 估计算法,采用原始信号作为模型输入,通过端到端学习直接从时域信号中提取 DOA 特征,避免了传统协方差矩阵方法在低信噪比环境下的性能退化问题。模型通过时空特征压缩和结合 Ghost 瓶颈结构减少参数量,并引入注意力机制自适应地重新标定特征通道权重,增强对关键特征的关注度。采用粗分类与细回归相结合的双分支输出策略,先确定角度区间再预测扇区内偏移量,从而在严苛条件下(如-5 dB 信噪比)仍能保持高精度估计。实验结果表明,该模型在保持优异性能(准确率 96.3%)的同时,实现了高度轻量化(模型实际部署大小 118.83 kB,参数量 24 783)。与传统算法和主流轻量化模型相比,本模型在降低模型参数量的基础上,同时保证了准确率和计算效率,为边缘设备提供了高精度、低延迟、低资源消耗的 DOA 估计解决方案。

**关键词:** DOA 估计;时域信号;协方差矩阵;轻量化模型;深度学习

**中图分类号:** TP391;TN911 **文献标识码:** A **国家标准学科分类代码:** 510.4020

## Signal DOA estimation based on lightweight cascading neural networks

Xiong Weihua Zhang Yong Zhang Xuemei Li Liangyao

(College of Electronics and Electrical Engineering (College of Intelligent Manufacturing), East China University of Technology, Nanchang 330013, China)

**Abstract:** Addressing the issues of existing deep learning-based direction of arrival (DOA) estimation algorithms, which suffer from large parameter volumes and dependence on covariance matrix inputs that are easily affected by noise, making deployment on resource-constrained edge devices challenging, this paper proposes a lightweight convolutional classification-regression neural network DOA estimation algorithm. The proposed method uses raw signals as model inputs and directly extracts DOA features from time-domain signals through end-to-end learning, thereby avoiding the performance degradation associated with traditional covariance matrix methods under low signal-to-noise ratio conditions. The model reduces the number of parameters through spatiotemporal feature compression and the integration of a Ghost bottleneck structure, and introduces an attention mechanism to adaptively recalibrate feature channel weights, enhancing focus on critical features. A dual-branch output strategy combining coarse classification and fine regression is adopted, first determining the angular interval and then predicting the sectoral offset, allowing for high-precision estimation even under stringent conditions (e.g., -5 dB SNR). Experimental results demonstrate that the model maintains outstanding performance (accuracy of 96.3%) while achieving high compactness (actual deployment size of 118.83 kB, with 24 783 parameters). Compared with traditional algorithms and mainstream lightweight models, this model preserves both accuracy and computational efficiency while reducing model parameter volume, providing edge devices with a high-precision, low-latency, and low-resource-consumption DOA estimation solution.

**Keywords:** DOA estimation; time domain signals; covariance matrix; lightweight model; deep learning

## 0 引 言

波达方向(direction of arrival, DOA)估计<sup>[1-4]</sup>是阵列信

号处理领域中的重要研究内容之一,DOA 估计的基本问题是确定空间内各个信号到达阵列的方向角。目前 DOA 估计广泛应用于无线通信、雷达、声呐等研究领域,并取得了

收稿日期:2025-09-09

\* 基金项目:江西省“双千计划”长期项目(DHSQT220210003)资助

长期的进展。

传统的 DOA 估计方法总体上是基于模型驱动的,其经典子空间算法主要有两类:一种是以重信号分类(multiple signal classification, MUSIC)算法为代表的噪声子空间算法<sup>[5]</sup>;另一种是以旋转不变子空间(estimating signal parameter via rotational invariance techniques, ESPRIT)算法为代表的信号子空间算法<sup>[6]</sup>,这些方法经历多年的研究具有扎实的理论基础和很好的估计效果,但因其是一类基于模型驱动的方法,其估计性能严重依赖于对阵列和传播环境先验知识的掌握程度。传统方法在理想条件下估计精度可以逼近克拉美罗界,但在实际环境中,往往由于物理条件的限制,存在着种种未知的误差因素,例如多径干扰、在幅度和相位上的未知阵列偏差等,这时候基于模型的估计方法性能会有所下降。

近年来,深度学习理论与方法的持续发展为 DOA 估计领域开辟了新的研究方向<sup>[7-10]</sup>。此类基于数据驱动的方法,通过构建网络模型直接从大量训练数据中学习阵列信号蕴含的关键信息,建立阵列输出与来波方向之间的非线性映射关系,最终实现对信号波达方向的估计。这种方法有效规避了传统方法所需依赖的信号模型构建过程,能够解决前述传统方法面临的诸多问题。目前 DOA 估计领域主要使用深度学习进行两方面的研究:一是直接使用神经网络对数据进行端到端的 DOA 估计<sup>[11-13]</sup>。代表性的有基于阵列协方差特征的 DOA 估计、基于稀疏先验特征的 DOA 估计等。二是使用神经网络对原始数据进行预处理<sup>[14-15]</sup>,将难以用常规方法去除的干扰和误差削弱之后,再使用传统的 DOA 估计算法进行求解。

现在基于深度学习的端到端 DOA 估计方法大多使用协方差矩阵或其变体作为输入,例如 Liu 等<sup>[16]</sup>提出采用包括实数和虚数协方差矩阵在内的双通道协方差矩阵作为 CNN 的输入信号,以估计水声信号的方向。郭书涵等<sup>[17]</sup>提出基于协方差矩阵输入的深度卷积神经网络的波达方向估计方法用来解决现有均匀线阵远场窄带非相干多目标估计算法对低信噪比、少快拍情况适应性差等问题。协方差矩阵包含相位差信息,模型可以从中提取特征并估计 DOA,但实际应用中协方差矩阵往往是不可知的,一般使用采样快拍估计得到采样协方差矩阵代替协方差矩阵。然而噪声的存在以及采样点数不足会影响采样协方差矩阵的准确性,采样协方差矩阵的不确定性会限制模型的特征提取能力,从而影响 DOA 估计的准确性。此外,现有深度神经网络 DOA 估计方法通常存在模型参数庞大、存储成本过高以及从信号变换成协方差矩阵计算开销高等问题。

本文一方面利用深度学习模型对原始信号数据的强大学习能力,将原始信号作为模型输入<sup>[18-19]</sup>来提取 DOA 信息,另一方面研究提出一种基于轻量化级联卷积神经网络的端到端 DOA 估计算法。该方法直接对原始信号进行处

理,通过设计时空分离卷积进行联合特征提取与压缩,显著降低数据维度;采用改动的 Ghost 卷积<sup>[20]</sup>与瓶颈结构在保证特征丰富性的前提下,大幅削减参数量与计算量。模型引入了轻量化的卷积块注意力机制<sup>[21-23]</sup>(convolutional block attention module, CBAM),从而在压缩冗余信息的同时,极大增强了与 DOA 估计相关的关键特征的表达。网络首先生成一个粗粒度的扇区分类输出,以确定来波方向的大致区间;随后,该分类结果引导一个专用的回归分支,对区间内的细微角度偏移进行精准预测;最终,通过一个可微的融合层将离散的分类结果与连续的回归值相结合,计算出高精度的最终角度。这种设计兼具了分类方法的鲁棒性与回归方法的精度优势。该设计降低了模型参数量、计算复杂度和存储需求,实现了轻量化目标。实验结果表明,该模型在准确率和精度方面表现优异,同时减小模型体积和参数规模,提升了计算效率,使其更适合部署在 STM32 单片机等资源受限的边缘计算设备上,有效满足实际应用需求。

## 1 理论基础

### 1.1 信号模型

基于传统算法的 DOA 估计大多通过建立模型给出阵列输出信号矢量及阵列导向矢量矩阵<sup>[24]</sup>从而得到信源的人射角度  $\theta_L$ , 假设有  $L$  个相互独立的远场窄带信号  $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_L(t)]^T$  同时入射到阵元间距为  $d$  的  $M$  元均匀线性阵列上,信号个数  $L < M$ ,其方向  $\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_L]^T$ , 则阵列输出  $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_M(t)]^T$  可写成:

$$\mathbf{y}(t) = \sum_{l=1}^L \alpha(\theta_L) s_L(t) + \mathbf{n}(t) = \mathbf{A}(\boldsymbol{\theta}) \mathbf{s}(t) + \mathbf{n}(t) \quad (1)$$

式中:  $\mathbf{n}(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T$  表示均值为 0; 方差为  $\sigma^2$  的高斯白噪声;  $\alpha(\theta_L)$  为阵列入射角为  $\theta_L$  的入射信号的导向矢量;  $\mathbf{A}(\boldsymbol{\theta})$  为阵列的导向矢量矩阵。其中  $\mathbf{a}(\theta_L)$  是第  $L$  个信号的方向向量,可以表示为:

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

$$\mathbf{A}(\boldsymbol{\theta}) = [\mathbf{a}(\theta_1), \mathbf{a}(\theta_2), \dots, \mathbf{a}(\theta_L)] \quad (3)$$

当阵列接收机采集到  $t = t_1, t_2, \dots, t_N$  时刻的  $N$  组快拍时,记  $\mathbf{Y} = [\mathbf{y}(t_1), \mathbf{y}(t_2), \dots, \mathbf{y}(t_N)] \in \mathbb{C}^{M \times N}$  为阵列观测矩阵,相应的信号波形  $\mathbf{S} = [\mathbf{s}(t_1), \mathbf{s}(t_2), \dots, \mathbf{s}(t_N)] \in \mathbb{C}^{K \times N}$ , 观测噪声  $\mathbf{N} = [\mathbf{n}(t_1), \mathbf{n}(t_2), \dots, \mathbf{n}(t_N)] \in \mathbb{C}^{M \times N}$ , 阵列响应矩阵  $\mathbf{A} = \mathbf{A}(\boldsymbol{\theta}) \in \mathbb{C}^{M \times L}$ 。因此,式(1)可重写为:

$$\mathbf{Y} = \mathbf{A}\mathbf{S} + \mathbf{N} \quad (4)$$

传统的 DOA 估计方法主要使用协方差矩阵进行估计。其需要从测量值  $\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(T)$  中估计出未知的信源波达方向  $\theta$ , 根据以上的假设,接收信号的协方

差矩阵。

$$\mathbf{R}_y = E[\mathbf{y}(t)\mathbf{y}^H(t)] = \mathbf{A}(\boldsymbol{\theta})\mathbf{R}_s\mathbf{A}^H(\boldsymbol{\theta}) + \sigma_e^2\mathbf{I}_N \quad (5)$$

式中:信源中所有角度是不相关的,信源协方差矩阵  $\mathbf{R}_s = E[\mathbf{s}(t)\mathbf{s}^H(t)] = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_K^2)$ ;  $\sigma_e^2$  为噪声功率。然而,在实际情况中,式(5)的协方差矩阵是未知的,取而代之的是它的样本协方差估计。

$$\tilde{\mathbf{R}}_y = \frac{1}{T} \sum_{t=1}^T \mathbf{y}(t)\mathbf{y}^H(t) \quad (6)$$

式中:  $\tilde{\mathbf{R}}_y$  为  $\mathbf{R}_y$  的无偏估计。

由协方差矩阵估计 DOA 的基本思想是利用阵列中不同阵元接收到的信号之间的空间关系。当信号到达阵列时,相邻阵元之间存在一定的间隔,导致不同阵元接收到的信号存在一定的相位差,这种相位差在协方差矩阵中会反映为不同位置的元素之间的相关性。但协方差矩阵估计会引入误差和复杂度,而式(4)表明接收信号  $\mathbf{Y}$  本身就包含每个窄带信号的 DOA 信息,因此本文研究直接利用接收信号  $\mathbf{Y}$  的 DOA 估计方法。

## 1.2 数据集构建

协方差矩阵包含了信号源在不同阵元中产生的相位差信息,现有的基于深度学习的 DOA 估计算法通常使用协方差矩阵或其变体作为神经网络的输入,通过提取这些信息来估计 DOA,获得了优于传统算法的性能。

将阵列输出的样本协方差矩阵作为输入。样本协方差矩阵是一个  $M \times M$  大小的复数矩阵,为正定 Hermitian 方阵。每个元素均为复数,对角线共轭对称元素对应的实部与虚部绝对值相等。因此分别提取协方差矩阵上三角元素的实部与下三角元素的虚部作为有用的信息用于神经网络训练。提取后的矩阵如式(7)所示。

$$\mathbf{R}_{feat} = \begin{bmatrix} \text{Re}(r_{11}) & \text{Re}(r_{12}) & \cdots & \text{Re}(r_{1M}) \\ \text{Im}(r_{21}) & \text{Re}(r_{22}) & \cdots & \text{Re}(r_{2M}) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Im}(r_{M1}) & \text{Im}(r_{M2}) & \cdots & \text{Re}(r_{MM}) \end{bmatrix} \quad (7)$$

然而,在 SNR 较低或采样点数较少的情况下,协方差矩阵中的信息可能会被噪声所覆盖,导致神经网络难以有效提取特征,从而产生较大的估计误差。所以本文研究直接将信号的实部虚部输入神经网络进行学习的新方法。具体来说,首先提取每个阵元接收信号的实部和虚部:

$$\mathbf{R}_m(n) = \text{Re}(\mathbf{y}_m(n)), \mathbf{I}_m(n) = \text{Im}(\mathbf{y}_m(n)) \quad (8)$$

其中,  $\mathbf{R}_m(n)$  和  $\mathbf{I}_m(n)$  是信号  $\mathbf{y}_m(n)$  的实部和虚部,  $\text{Re}(\mathbf{y}_m(n))$  和  $\text{Im}(\mathbf{y}_m(n))$  是提取  $\mathbf{y}_m(n)$  实部和虚部的计算。然后将其以一个三维数组形式输入进构建的神经网络模型中。

所得数组  $\mathbf{M}_{Rl}$  的维数为  $(M, N_s, 2)$ , 将其作为神经网络的输入。这种方法不需要计算协方差矩阵的过程,直接从原始信号实部虚部中提取信息,有望获得更好的 DOA 估计结果。

$$\mathbf{M}_{Rl} = \begin{bmatrix} R_1(0) & R_1(1) & \cdots & R_1(N_s - 1) \\ R_2(0) & R_2(1) & \cdots & R_2(N_s - 1) \\ \vdots & \vdots & \vdots & \vdots \\ R_M(0) & R_M(1) & \cdots & R_M(N_s - 1) \\ I_1(0) & I_1(1) & \cdots & I_1(N_s - 1) \\ I_2(0) & I_2(1) & \cdots & I_2(N_s - 1) \\ \vdots & \vdots & \vdots & \vdots \\ I_M(0) & I_M(1) & \cdots & I_M(N_s - 1) \end{bmatrix} \quad (9)$$

本文训练数据参考了文献[9,16],考虑到模拟实际实验测试条件和环境,仿真条件设置为 6 阵元的均匀线阵,阵元间距为  $\lambda/2$ , 待估信号源 DOA 范围为  $[-60^\circ, 60^\circ]$ , 快拍点数  $N=256$ 。以  $1^\circ$  为网格密度,生成一个具有 121 个人射角度的数据集。为了使得模型能够在不同信噪比下得到优异的表现,本文将生成不同信噪比下的数据用于训练。从  $-10 \sim 20$  dB,每隔 2 dB 生成训练数据。在每种信噪比的环境下,每个角度生成 100 个样本,每个样本都是加上对应信噪比的随机高斯白噪声,相当于每种信噪比的环境下 12 100 个数据作为神经网络的训练数据,针对 16 组信噪比,共 193 600 组数据用作训练。其中训练集与测试集按照 8:2 的比例随机选取。

## 2 基于轻量化级联神经网络的 DOA 估计方法

### 2.1 网络结构

本文构建了一个用于 DOA 估计的轻量化神经网络模型。该模型接收形状为  $(M, N, 2)$  的原始信号输入,其整体架构及算法流程如图 1 所示,主要有:一个快速预处理卷积层、一个阵列空间压缩层、两个改进的 Ghost 瓶颈模块、一个复合注意力模块和一个分类-回归协同输出层。

预处理卷积层优先对时间维度进行特征提取和降采样。空间压缩层将  $M$  个阵元信号融合为一个虚拟信号,使后续计算专注于时间维度特征。两个 MGbneck-SE 模块进一步提取特征并下采样,其末端引入 SE 注意力机制增强特征选择能力。复合注意力模块引导模型聚焦于关键特征。最后采用分类-回归协同输出层,一个分支输出扇区的类别概率;另一个分支回归扇区内的连续偏移量。最终角度估计值由两者计算得出。此设计将连续的回归问题转化为离散分类与精细回归的结合,降低了模型学习难度。

整个模型的构建兼顾了性能和效率,特别适合在资源受限的嵌入式设备上运行。通过分类-回归协同输出降低学习难度和注意力机制,模型在低信噪比环境下也能保持较高的估计精度。模型结构和主要参数如表 1 所示。

### 2.2 时空特征联合提取模块

时空特征联合提取模块作为整个模型的前端处理层,承担着从原始阵列信号中提取关键时空特征的核心任务。该模块采用两级级联处理策略:

通过一个时间维度专用卷积层(核尺寸为  $1 \times 7$ ,步长为  $(1, 4)$ )沿时间轴进行高密度特征提取与降采样。该操作

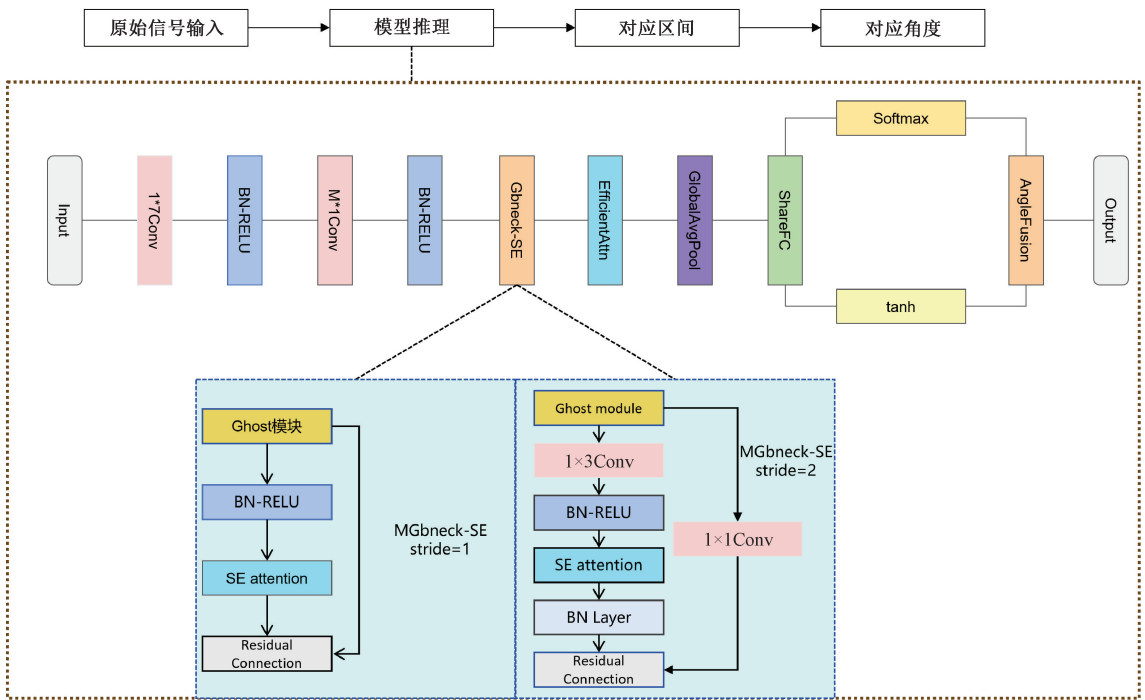


图 1 模型结构与算法流程

Fig. 1 Model structure and algorithm flow

表 1 模型主要结构及参数

Table 1 The main structure and parameters of the model

层	操作	步长	是否加入下采样	参数量
输入层				
首层卷积	$1 \times 7\text{Conv}$	(1,4)	是	224
批量归一化层				64
空间压缩卷积	$M \times 1\text{Conv}$	(1,1)		$384 \times M$
MGbnck 块 1	瓶颈结构	(1,2)	是	5 632
MGbnck 块 2	瓶颈结构	(1,2)	是	12 096
高效注意力模块				624
全局池化层				0
分类-回归共享连接层				6 029

通过在时间窗口内捕捉相位差和信号演变规律,在保留关键声学模式的同时,将时间维度长度降至原始的  $1/4$ ,大幅压缩后续计算量。接着采用一个空间压缩卷积层(核尺寸为  $M \times 1$ ,  $M$  为麦克风阵元数量,步长为 (1,1))沿阵列空间维度进行特征聚合。该层以 padding='valid' 模式工作,其物理意义是将所有  $M$  个阵列的接收信号投影融合为一个全局性的通道特征,从而将空间维度从  $M$  压缩为 1,实现了多通道信息到单一维度表征的凝练。

这种时空分离的处理架构既能充分挖掘信号在时间演化中的相位变化规律,又能有效捕捉阵列间的空间相关性(相干性),最终生成高度凝练的  $(1, N/4, 24)$  维时空特征图。每个处理阶段均严格遵循卷积-批归一化-ReLU 激活的标准流程,确保特征分布的稳定性并增强非线性表达能

力,为后续的深度特征处理奠定坚实基础。通过这种结构上的先验设计,该模块在源头就实现了计算效率的优化,使其能够在嵌入式设备上实现实时 DOA 估计。

### 2.3 MGhost 瓶颈结构

在声源方向估计任务中,特征图往往包含一定的时空冗余信息,这些冗余特征在提升网络表征能力的同时也增加了计算负担。与传统轻量化方法直接剔除冗余特征不同,本模型采用的 ghost 卷积创新性地通过低成本变换策略保留这些特征。两者区别如图 2 所示。

其核心思想是利用初级特征图通过轻量级线性操作衍生出“幽灵特征图”(ghost feature maps),在维持模型性能的同时显著降低计算复杂度。具体而言,对于一个输入特征图,与传统卷积直接处理不同,Ghost 卷积首先通过一

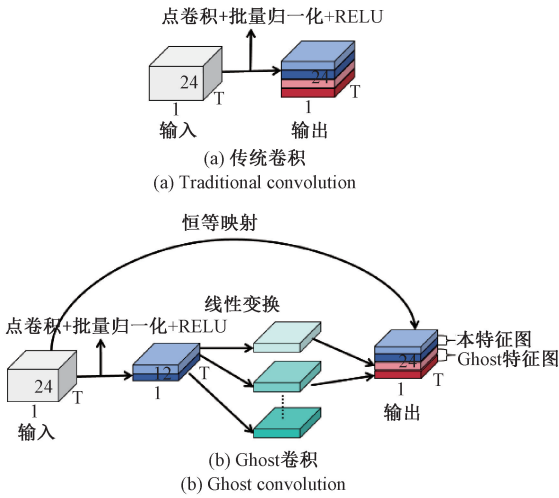


图 2 传统卷积和 Ghost 卷积工作流程对比  
Fig. 2 Comparison of the workflow of traditional convolution and Ghost convolution

个廉价的  $1 \times 1$  卷积生成少量通道的“原始特征图” (intrinsic features), 其通道数约为目标输出通道数的一半 (由压缩比率 ratio 决定)。随后, 对这批原始特征图中的每个通道, 施加一系列轻量的线性操作 (如  $1 \times 3$  深度卷积) 来生成所需的“幽灵特征图” (ghost features)。该操作在不改变特征图时空尺寸的前提下, 高效地丰富了特征表征。最终, 将原始特征图与幽灵特征图在通道维度上进行拼接, 即可得到与标准卷积输出尺寸相同但计算成本更低的特征图。

本文在 ghost 卷积的基础上, 修改了 ghost 网络中的瓶颈结构, 降低参数量使之更加适合实时 DOA 估计任务。改动后的瓶颈结构统一称为 MGhost 瓶颈结构。MGhost 瓶颈结构如图 3 所示, 同样包含两种类型:  $strides=1$  的基本结构和  $strides=2$  的下采样结构。

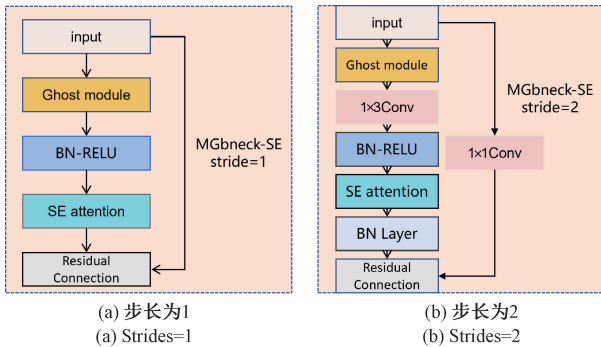


图 3 MGhost 瓶颈结构  
Fig. 3 MGhost bottleneck structure

在  $strides=1$  的 MGhost 瓶颈中, 主路径通过 MGhost 卷积模块实现特征变换: 首先使用  $1 \times 1$  卷积压缩并提炼特征, 再经  $1 \times 3$  深度卷积生成幽灵特征图, 随后将两部分沿通道拼接。若通道数不符, 则以  $1 \times 1$  卷积对齐, 再经 SE

模块进行通道加权以增强方位敏感特征。最终通过残差连接与 shortcut 分支相加 (输入通道不匹配时, shortcut 经  $1 \times 1$  卷积调整), 以促进梯度流动并降低过拟合。

在  $strides=2$  的下采样结构中, 主路径先执行相同 MGhost 卷积, 再通过步长为 2 的  $1 \times 3$  卷积在时间维度下采样, 减少序列长度。随后经 SE 注意力机制加权以突出关键时空特征。shortcut 分支使用步长为 2 的  $1 \times 1$  卷积同步实现下采样与通道调整, 最终通过残差加法完成特征融合, 保持信息完整性。

该设计通过单一模块高效完成通道变换与特征提炼, 利用标准卷积实现稳健下采样, 并在特征变换后引入注意力机制, 从而在保持模型 DOA 估计准确率的同时, 削减参数量与计算复杂度。经优化后的网络极大提升了声源定向的计算效率, 使其更适合在计算资源受限的嵌入式平台中实时部署与应用。

### 2.4 多重注意力机制

本模型使用了两种注意力机制<sup>[25]</sup>, 通过层级化特征增强策略提升声源方向估计性能。在瓶颈结构阶段, 采用 SE (squeeze-and-excitation) 注意力结构对特征通道进行动态重校准。如图 4 所示, 该机制通过全局平均池化将尺寸为  $H \times W \times C$  的时空特征图压缩为  $1 \times 1 \times C$  的通道描述符; 随后经过两级全连接层构成的瓶颈结构, 首层将通道维度压缩至原始尺寸的  $1/4$ , 次层恢复原始维度, 通过这种“压缩-扩展”策略建模通道间非线性依赖关系; 最终通过 Sigmoid 激活生成通道权重向量, 与原始特征图进行逐通道相乘, 实现特征通道的自适应增强。




图 4 SE 注意力机制结构  
Fig. 4 SE attention mechanism structure

在后续层中, 模型引入复合注意力模块如图 5 所示, 协同优化通道与空间注意力。




图 5 复合注意力模块结构  
Fig. 5 Composite attention module structure

该模块首先通过全局平均池化和全连接层生成通道权重; 利用  $1 \times 1$  卷积压缩空间维度, 生成空间注意力热力图。随后进行串联加权: 先将通道权重与特征逐通道相乘, 增强关键通道; 再将结果与空间注意力图逐元素相乘,

聚焦关键区域。该注意力机制可强化方向敏感的时空特征,提升在复杂声学环境下对声源方位信息的捕获能力,有效抑制噪声干扰并增强相位差特征表达,从而提升 DOA 估计的精度与鲁棒性。

## 2.5 分类-回归协同输出层

该模型的输出层其采用了“分治策略”(divide-and-conquer)的混合输出层设计,结合了分类任务的鲁棒性与回归任务的精确性,以期实现高精度且稳定的波达方向(DOA)估计。

具体而言,该设计将连续的 DOA 估计问题分解为两个子任务:粗分类(coarse classification):首先,一个分支会执行 12 类分类,将整个方位角空间(如  $-60^\circ \sim 60^\circ$ )划分为 12 个离散的扇区。此步骤旨在快速确定目标声源所在的大致角度区间(例如是位于  $-25^\circ \sim -35^\circ$  的区间内)。分类输出具有内在的鲁棒性,能有效避免回归任务中容易出现的“模式崩溃”或对异常值敏感的问题,确保了模型预测结果始终落在合理的物理范围内。细回归(fine regression):在确定大致扇区后,另一个回归分支并非直接预测绝对角度,而是预测一个相对于其扇区中心的精细偏移量。该偏移量被限制在一个较小范围内(如  $\pm 5^\circ$ ),并使用 tanh 激活函数将其输出规范到  $[-1, 1]$  区间,再缩放为实际的角度偏移值。这种设计降低了回归任务的难度,让模型只需学习一个细微的、局部的校正量。最终,预测角度由两部分协同计算得出:最终角度 = 扇区中心角度 + 缩放后的偏移量。这种“先分类定位,再回归微调”的架构,兼具了分类的稳定性和回归的精度。

## 3 仿真实验与结果分析

### 3.1 实验环境与配置说明

本文实验平台为 64 位 Window11 系统,搭配使用 Intel(R) Core(TM) i7-14700HX 2.10 GHz 的 CPU 和 NVIDIA GeForce RTX 4060 的 GPU,机带 RAM 为 16 GB,使用 Pycharm2023.1 开发环境搭配 python3.9.19 版本,基于 Tensor-flow2.10 版本的深度学习框架,使用 Keras 库函数。下面所有实验中一律采用 RS 缩写代表原始信号输入,CM 缩写代表协方差矩阵输入。

本文采用 MUSIC 算法、MobileNetV2 算法、GhostNet 算法、与本文所提基于轻量化级联神经网络的 DOA 估计算法进行对比。MUSIC 算法是对阵列输出的协方差矩阵进行特征分解,利用信号子空间和噪声子空间的正交性进行划分空间,构造空间谱函数,搜索其谱峰实现 DOA 估计。而 MobileNetV2 算法、GhostNet 算法均是近些年提出的轻量化模型代表,选取这几种算法不仅保证了对比的严谨性,同时也保证了对比的多样性和广泛性。以上几种方法在低信噪比、少快拍的情况下存在适应性差,无法准确进行 DOA 估计等问题,本文设计的基于轻量化级联神经网络的 DOA 估计算法估计综合来看能有效提高 DOA

估计性能。

### 3.2 不同信号输入与模型训练对比

在正式实验之前,本文对两种信号输入在不同信噪比下所包含信息进行对比来观察两种信号输入的特点。结果如图 6 所示。




图 6 不同输入信息熵对比

Fig. 6 Comparison of different input information entropy

从两种信号输入对比图像中可以看出:1)原始信号输入包含的信息熵始终大于协方差矩阵输入,协方差矩阵本身就是由原始信号经过处理变换而来,所以根据信息论经过处理处理的信号其所包含的信息不可能大于原本信号。2)随着信噪比增大,两种输入包含的信息熵值呈现先减小逐渐趋于相同趋势,这是因为随着信噪比增大,噪声减小,信号本身占据主导地位,协方差矩阵本身由原始信号经过处理得到,信噪比越高两者的差距越小。综上所述,也可以看出,对于模型训练来说,原始信号包含的特征更多,尤其是在低信噪比下,这样训练出来的模型抗干扰能力以及其他能力会更强,这也与后续实验结果相佐证。

在训练阶段,设定过高的轮次(epoch)可能导致过拟合,为避免该问题,这里将 epoch 设置为 100。选择合适的批量大小影响着模型的训练速度和资源消耗,过小会阻碍收敛,过大会消耗大量内存资源,这里将批量大小设置为 128。优化器选择 Adam 优化器,初始学习率设置为 0.001,损失函数选择交叉熵损失函数,该函数在量化模型预测值与真实值之间的差异方面表现出色,有助于提高模型的拟合能力和预测准确性。各模型验证集准确率如图 7 所示。

为了体现对比的意义和准确,本文将参与对比的模型算法在本身为轻量化模型的基础上进行了一定的轻量化,使得各模型参数在同一量级,并均能部署进单片机中测试。将训练后的模型大小、准确率、参数量等参数记录在表 2 中。

### 3.3 消融实验

本文通过消融实验研究 Mghost 结构中压缩比率与线性操作对 DOA 特征提取的影响机理。实验基于不同压缩比率(ratio)和线性操作配置的 Mghost 模块展开,并将模块堆叠次数固定为 2。实验以角度估计均方误差(RMSE)、

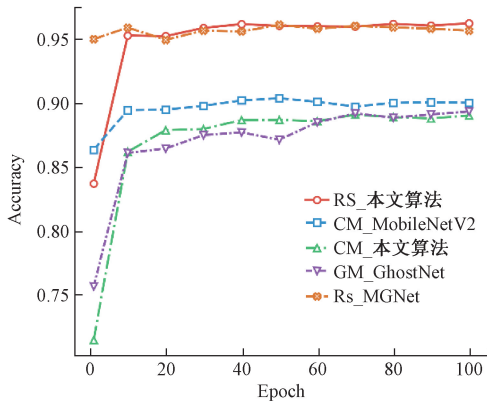


图 7 各模型验证准确率

Fig. 7 Accuracy of each model verification

模型大小和参数量作为核心评价指标,具体实验结果如表 3 所示。

通过对比分析,旨在评估不同配置在 DOA 任务中的特征提取效率及其对计算资源的占用情况。从表 3 中可

表 2 各模型参数性能

Table 2 Performance of various model parameters

网络模型	准确率/ %	参数量	模型 大小/MB
RS_本文算法	96.33	24 783	0.577
CM_MobileNetV2	89.98	32 745	0.598
CM_本文算法	89.13	42 182	0.765
CM_GhostNet	89.30	30 719	0.610
RS_GMNet	95.64	25 703	0.580

以看出:1)当线性操作类型不变时,随着 ratio 增大,参数量和准确率都有所下降,但由于 ratio 增大,廉价操作增多,所以整个模型大小增大,由于实际部署内存有限,所以综合所有因素考虑,选择 ratio=2 是最佳选择。2)当 ratio 相同时,选择标准卷积操作时,相比深度卷积,参数量增大,模型大小增大,而准确率提升不明显,综合所有因素,选择深度卷积操作时最佳选择。所以综上所述,选择深度卷积操作+ratio=2 的组合作为本文提出算法的最佳搭配。

表 3 MGhost 结构消融实验

Table 3 MGhost structural ablation experiment

线性操作类型	压缩比率(ratio)	准确率/%	模型大小/MB	参数量	FLOPs
深度卷积	1	96.6	0.570	27 346	1 326 642
	2	96.5	0.593	26 176	1 227 570
	3	96.3	0.623	25 786	1 194 546
	4	96.0	0.638	25 591	1 178 034
标准卷积	2	96.5	0.623	28 750	1 451 058
	3	96.4	0.648	28 018	1 388 082
	4	96.2	0.675	27 427	1 337 010

本文通过消融实验研究各种注意力机制对模型性能的影响。实验基于引入了 SE 注意力机制的 MGhost 模块以及高效注意力机制展开,并将模块的堆叠次数固定为 2。实验以准确率、模型大小和参数量作为核心评价指标,具体实验结果如表 4 所示。

表 4 注意力机制消融实验结果

Table 4 Ablation experiment results of the attention mechanism

SE 注意力 模块	复合注意力 模块	准确率/ %	模型 大小/MB	参数量
		95.5	0.506	24 539
✓		95.8	0.557	25 497
	✓	96.0	0.543	25 218
✓	✓	96.5	0.593	26 176

实验结果表明,在不引入注意力机制的情况下,模型的准确率最低,仅为 89.4%。当分别引入 SE 注意力模块

和复合注意力模块时,模型的准确率分别提升至 95.8%和 96.0%,同时引入复合注意力模块所增加的参数量和模型大小均小于 SE 注意力模块,突出了复合注意力模块的优势,进一步实验表明,同时引入两种注意力模块,模型的准确率提升至 96.5%,优于单独引入一种注意力机制。同时参数整体上对于一种模块都不引入的模型来说,仅增加了 1 637,所以综合来看,选择使用多重注意力机制的模块最佳。

同时本文还对注意力权重在不同角度上进行了可视化处理。可视化结果如图 8、9 所示。

从通道角度特异性分析图中能更加直观看到注意力机制在工作情况,不同通道会针对某些入射角度有着极高的权重,这表明其对 DOA 关键特征增强的实际作用。通过多种注意力机制对比结果图可以看出,每个不同角度区域,不同通道的权重分配不一样,对应的空间注意力机制也有相应的侧重点。

3.4 结果分析

通常使用均方根误差(RMSE)来度量 DOA 估计性

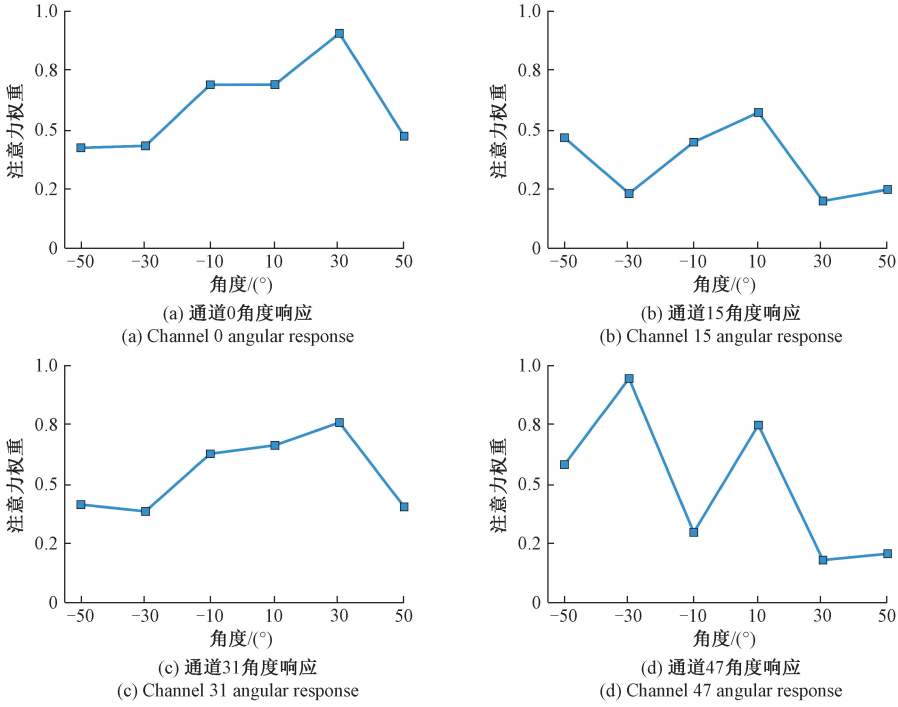


图8 不同角度通道注意力权重

Fig. 8 Attention weights of channels from different angles

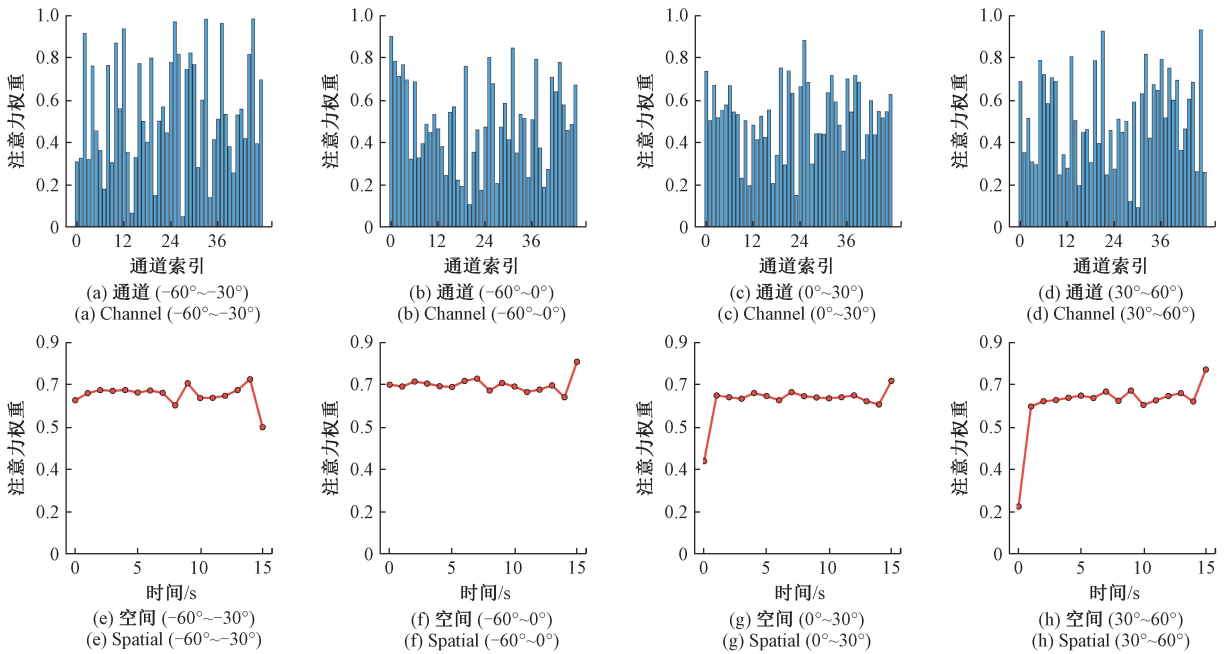


图9 多种注意力机制对比结果

Fig. 9 Comparison results of various attention mechanisms

能,定义:

$$RMSE = \sqrt{\frac{1}{EK} \sum_{k=1}^K \sum_{m=1}^M (\theta_k^{(e)} - \hat{\theta}_k^{(e)})^2} \quad (10)$$

式中:  $[\theta_1^{(m)}, \theta_2^{(m)}, \dots, \theta_k^{(m)}]^T$  为 DOA 的实际值; DOA 的测

量值为  $[\hat{\theta}(m)_1, \hat{\theta}_2^{(m)}, \dots, \hat{\theta}_k^{(m)}]^T$ ;  $K$  为信源个数;  $M$  为每次实验时的测试样本总数。

克拉美罗下界(Cramér-Rao lower bound, CRLB)则用于评估一个无偏估计方法的有效性。该界限描述了在给

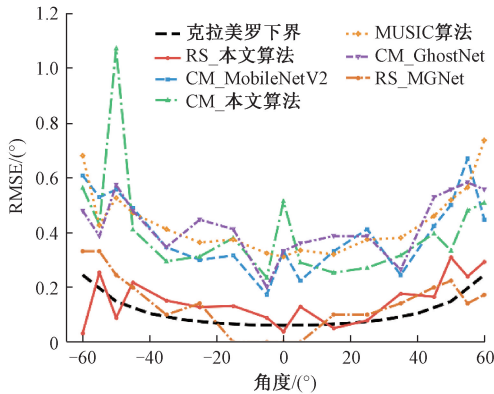
定一组观测数据和模型的条件,对参数进行估计的理论上可能达到的最小方差,即指利用已有信息估计参数所能达到的最好效果。当阵列间距相同时,阵列为均匀线性阵列,信源个数为单个时,此时角度估计的克拉美罗下界为:

$$CRLB(\theta) = \frac{6}{\left(\frac{2\pi d}{\lambda}\right)^2 SNR NM(M^2 - 1)\cos^2\theta} \quad (11)$$

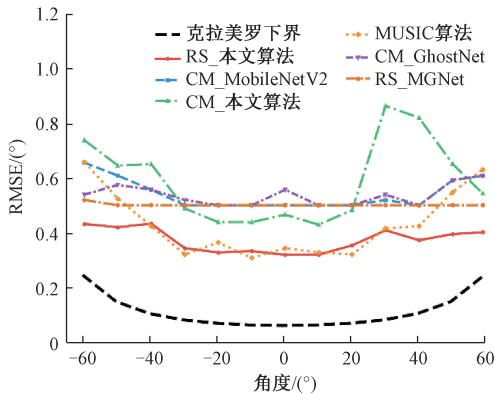
其中,SNR 为信号的信噪比,  $N$  为采样快拍,  $M$  为阵元数。

1) 不同情况下不同角度对 DOA 估计性能的影响

在该实验中,比较了模型“在网(ongrid)”和“离网(offgrid)”两种情况下的性能。“在网”是指测试数据的 DOA 在训练集中出现过,“离网”是指测试数据的 DOA 没有在训练集中出现过。结果如图 10 所示。测试集 SNR=0 dB,快拍为 256,每个 DOA 下产生 100 个测试样本。并根据公式,给出了克拉美罗下界(从图 10 可以看出其曲线会随着两边角度的增大而增大)由图 10 可知,所有方法曲线的 RMSE 都随着角度增大呈现增大趋势,即入射角度越大估计效果会变差,符合实际的物理情况,这也是本文选



(a) “在网”不同模型与算法 DOA 估计性能  
(a) DOA estimation performance of different models and algorithms “online”



(b) “离网”不同模型与算法 DOA 估计性能  
(b) DOA estimation performance of ‘off-grid’ different models and algorithms

图 10 不同情况下不同模型与算法 DOA 估计性能

Fig. 10 DOA estimation performance of different models and algorithms under different conditions

取 $[-60^\circ, 60^\circ]$ 范围内入射信号作为数据集的原因。从图中可以得出以下结论:(1)在网情况下采用原始信号输入的模型其 RMSE 低于采用协方差矩阵输入的模型和传统算法。(2)在网情况下采用相同输入方式下,本文设计的模型相比经典轻量化模型除了个别误差外,整体 DOA 估计性能略优于经典的轻量化模型传统算法。(3)在离网情况下,分类模型受到网格限制,相同输入下,本文模型 DOA 估计性能要优于分类模型,展现了良好的泛化能力。采用原始信号输入的模型方法中,对于分类模型其 RMSE 稳定在 0.5 左右,本文模型则整体低于 0.5,相比采用协方差矩阵输入的方式,其 DOA 估计稳定性和泛化能力以及准确率都有所提高。

2) 信噪比(SNR)对 DOA 估计性能的影响

在该实验中,测试数据集 SNR 范围在 -12 dB ~ 20 dB,间隔为 2 dB,每个 SNR 下每个角度生成 10 个测试样本,故每个 SNR 下有 1 210 个测试样本。不同 SNR 下 6 种方法的 DOA 估计 RMSE 曲线如图 11 所示。

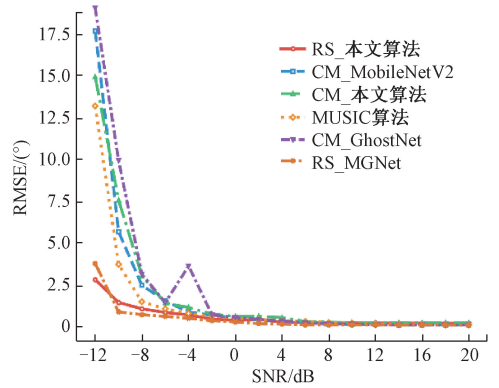


图 11 信噪比(SNR)对不同算法 DOA 估计性能的影响

Fig. 11 The impact of signal-to-noise ratio (SNR) on the DOA estimation performance of different algorithms

从图中可以得出以下结论:(1)6 种方法的 RMSE 都随着 SNR 的增加而减小;在高 SNR 区域,随着 SNR 的进一步增大, RMSE 的下降趋势明显放缓。(2)在低 SNR 区域,对比 CM\_本文算法和 RS\_本文算法以及 RS\_MGNet 可以看出,采用原始信号输入的方法的 DOA 估计性能在低信噪比的情况下要明显优于采用协方差矩阵输入的方法。(3)同样的输入方式下,结合后续表格统计,本文设计模型在计算复杂度低于其他模型情况下,整体精度与其他模型方法相近。在未经训练的 SNR(如 -12 dB)的样本中,本文所提出方法依然可以获得较低的 RMSE,这表明所提方法具有良好的泛化能力。

3) 快拍数对 DOA 估计性能的影响

在该实验中,测试集 SNR=0 dB,每个 DOA 下产生 10 个测试样本,快拍数  $N$  分别为 16、32、64、128、256、512、1 024。则每种快拍数下有 1 210 个样本。不同采样点数下 6 种方法的 RMSE 曲线如图 12 所示。由图 12 可知:

(1) 6 种方法的 RMSE 都随着快拍增大而减小, 高快拍下, 快拍增大到一定值后, RMSE 下降趋势基本停止。(2) 在低快拍下, 相同快拍使用原始信号输入的方法其 RMSE 要低于使用协方差矩阵输入方法, 代表采用原始信号输入的方法 DOA 估计性能更优。(3) 在低快拍下, 相同快拍使用相同输入的方法, 本文设计模型其 RMSE 要低于传统分类模型方法, 代表采用本文设计模型的方法 DOA 估计性能更优。(4) 所有模型本身采用的是 256 快拍进行训练, 其他快拍数据对模型来说属于未经训练的数据, 因此模型方法在低快拍下 RMSE 要高于传统算法。

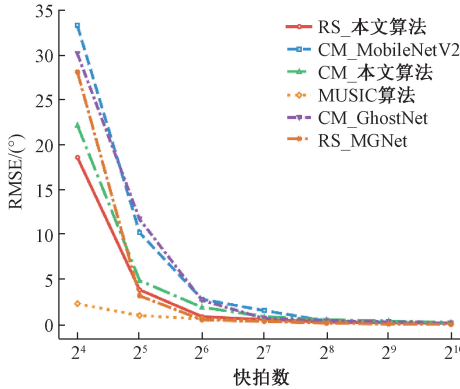


图 12 快拍数对不同模型 DOA 估计性能的影响

Fig. 12 The impact of snapshot numbers on the DOA estimation performance of different models

#### 4) 不同方法运行时间与复杂度统计

在电脑上测试了各种算法所需的平均运行时间以及统计了推理整个过程计算量, 具体做法是记录上述 6 种方法独立运行 1 000 次的时间并求得平均值, 并记录整个过程中的 FLOPs, 结果如表 5 所示。

表 5 不同算法运行时间与复杂度的比较

Table 5 Comparison of run time and complexity of different algorithms

网络模型	推理时间/ms	推理 FLOPs
RS_本文算法	0.322 7	1 148 454
RS_GMNet	0.324 9	2 142 184
CM_MobileNetV2	0.302 1	215 910
CM_本文算法	0.290 2	159 319
CM_GhostNet	0.351 3	334 694
MUSIC 算法	2.804 7	167 112

基于 DL 的方法的计算复杂度取决于网络本身构成和输入数据尺寸, 由于本文所采用原始信号输入其尺寸远大于协方差矩阵输入所以导致本文所用方法计算量大于采用协方差矩阵输入的方法和传统算法, 但是对比采用同样输入的分类模型, 本文模型的设计相应的降低了参数量, 且整体所花费的推理时间与其他方法相近, 优于传统算

法, 结合前文所述的优势, 整体来看本文采用的输入方式和模型设计相比其他设计更优。

本文的模型部署工作主要基于 STM32CubeMX 开发平台及其扩展组件 X-CUBE-AI 完成。目标硬件平台选用 NUCLEO-L476RG 开发板具有 128 kB SRAM 和 1 MB Flash 存储器, 适合运行轻量化神经网络模型。选取了本文算法以及 GhostNet 进行实际部署测试, 得到的测试结果如表 6 所示。

表 6 不同算法实际部署数据

Table 6 Actual deployment data of different algorithms

网络模型	flash	RAM	推理	推理
	占用/kB	占用/kB	时间/s	功耗/次
本文算法	118.8	43.7	1.4	0.045
GhostNet	151.1	43.1	0.6	0.026

在 CubeMX 开发平台进行模型部署, 其会对模型有一定压缩效果, 所以实际部署大小与前文所提模型大小会有所不同。根据表中内容可知本文算法可以部署进所选单片机中并正常工作, 整体功耗较低, 由于没有硬件加速以及本文算法采用原始信号输入而 GhostNet 采用协方差矩阵输入, 数据维度上存在差异, 本文算法推理时间较长, 但考虑到上述实验中准确率的提升效果以及在低信噪比下的识别效果, 本文算法依旧可以作为一种不错的选择。

## 4 结 论

本文针对现有基于深度学习的波达方向 (DOA) 估计算法存在参数量大、依赖易受噪声干扰的协方差矩阵输入, 难以部署于资源受限的边缘设备的问题。本文提出一种基于原始信号输入的轻量化卷积级联神经网络 DOA 估计算法。该方法创新性地采用原始信号作为输入, 通过端到端学习直接从时域信号中提取 DOA 特征, 避免了传统协方差矩阵方法在低信噪比环境下的性能退化问题。模型通过时空特征压缩和结合 Ghost 瓶颈结构减少参数量, 并引入注意力机制自适应地重新标定特征通道权重, 增强对关键特征的关注度。采用粗分类与细回归相结合的双分支输出策略, 先确定角度区间再预测扇区内偏移量, 在 -5 dB 信噪比下仍保持高的估计精度。实验表明, 本文设计方法在保持 96.3% 角度估计准确率的同时, 优于 GhostNet、MobileNet 系列等对比模型和传统算法。这种“原始信号输入-轻量特征提取-注意力增强-多任务协同”的架构, 为资源受限的边缘设备提供了高精度、低延迟的 DOA 估计解决方案。

## 参考文献

[1] LONG J, WANG X, ZHOU W, et al. A comprehensive review of signal processing and machine

- learning technologies for UHF PD detection and diagnosis (I): Preprocessing and localization approaches[J]. *IEEE Access*,2021,9: 69876-69904.
- [2] 单泽彪,薛泓垚,刘小松,等.基于双曲复合函数近似  $l_0$  范数的 DOA 估计[J]. *电子测量技术*,2023,46(22): 49-55.
- SHAN Z B, XUE H Y, LIU X S, et al. DOA estimation based on hyperbolic composite function approximation  $l_0$  norm [J]. *Electronic Measurement Technology*,2023,46(22): 49-55.
- [3] LONG J, WANG X. A comprehensive review of signal processing and machine learning technologies for UHF PD detection and diagnosis (II): Pattern recognition approaches[J]. *IEEE Access*,2024,12: 29850-29890.
- [4] 刘其有,何瑞,施伟.基于深度学习的波达方向估计方法综述[J]. *中国电子科学研究院学报*,2025,20(1): 1-9.
- LIU Q Y, HE R, SHI W. A survey of DOA estimation methods based on deep learning[J]. *Journal of China Academy of Electronic Science*,2025,20(1): 1-9.
- [5] 钟东强.基于深度学习与小尺寸麦克风阵列的 DOA 估计研究[D].成都:四川大学,2023.
- ZHONG D Q. Research on DOA estimation based on deep learning and small-sized microphone array[D]. Chengdu:Sichuan University,2023.
- [6] 范文泉,肖文书.基于 MUSIC 和 ESPRIT 算法的 DOA 动态布站[J]. *电子测量技术*,2019,42(2):142-148.
- FAN W Q, XIAO W SH. DOA dynamic deployment based on MUSIC and ESPRIT algorithm [J]. *Electronic Measurement Technology*, 2019, 42 (2): 142-148.
- [7] HUANG Y, ZHANG Y, TAO J, et al. Off-grid DOA estimation via a deep learning framework[J]. *Science China Information Sciences*,2023,66(12): 222305.
- [8] 赵承庚.基于深度神经网络的 DOA 估计[D].哈尔滨:哈尔滨工业大学,2022.
- ZHAO CH G. Direction of arrival estimation based on deep neural network[D]. Harbin: Harbin Institute of Technology,2022.
- [9] 范大照,章勇,熊伟华,等.基于轻量化卷积神经网络的 DOA 估计[J]. *机电工程技术*,2025,54(7):60-64.
- FAN D ZH, ZHANG Y, XIONG W H, et al. DOA estimation based on lightweight convolutional neural network [J]. *Mechanical and Electrical Engineering Technology*,2025,54(7): 60-64.
- [10] 张彪,荀荣科,许家忠.基于深度学习的工业轴承缺陷检测算法研究[J]. *仪器仪表学报*,2025,46(4): 136-149.
- ZHANG B, XUN R K, XU J ZH. Research on industrial bearing defect detection algorithm based on deep learning [J]. *Chinese Journal of Scientific Instrument*,2025,46(4): 136-149.
- [11] WU L, LIU Z M, HUANG Z T. Deep convolution network for direction of arrival estimation with sparse prior [J]. *IEEE Signal Processing Letters*, 2019, 26(11): 1688-1692.
- [12] 俞帆,陈格格,沈明威.基于双通道复数卷积神经网络的 DOA 估计算法[J]. *现代雷达*,2022,44(12):81-86.
- YU F, CHEN G G, SHEN M W. DOA estimation algorithm based on dual-channel complex convolutional neural network [J]. *Modern Radar*, 2022, 44 (12): 81-86.
- [13] XU X, HUANG Q. MD-DOA: A model-based deep learning DOA estimation architecture [J]. *IEEE Sensors Journal*,2024,24(12): 20240-20253.
- [14] 刘阿飞,师俊朋,张双辉,等.基于复值卷积网络的阵列 DOA 估计[J]. *现代雷达*,2022,44(5):64-71.
- LIU A F, SHI J P, ZHANG SH H, et al. Array DOA estimation based on complex-valued convolutional network [J]. *Modern Radar*,2022,44(5): 64-71.
- [15] CAI R, TIAN Q, GUO S. DOA estimation via Toeplitz covariance matrix in the presence of impulsive noise[J]. *Signal, Image and Video Processing*, 2025, 19(10): 1-10.
- [16] LIU Y, CHEN H, WANG B. DOA estimation based on CNN for underwater acoustic array [J]. *Applied Acoustics*,2021,172: 107594.
- [17] 郭书涵,胡国平,赵方正,等.基于深度卷积神经网络的 DOA 估计[J]. *空军工程大学学报*,2023,24(4): 62-68.
- GUO SH H, HU G P, ZHAO F ZH, et al. DOA estimation based on deep convolutional neural network [J]. *Journal of Air Force Engineering University*,2023,24(4): 62-68.
- [18] ZHENG S, YANG Z, SHEN W, et al. Deep learning-based DOA estimation [J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(3): 819-835.
- [19] CHEN P, CHEN Z, LIU L, et al. Sdoa-net: An efficient deep-learning-based doa estimation network for imperfect array [J]. *IEEE Transactions on Instrumentation and Measurement*,2024,73: 1-12.
- [20] 赵志宏,郝子晔,何朋.融合注意力机制与 GhostUNet 的路面裂缝检测方法[J]. *电子测量技术*,2023, 46(24):164-171.
- ZHAO ZH H, HAO Z Y, HE P. Pavement crack detection method based on attention mechanism and

- GhostUNet[J]. *Electronic Measurement Technology*, 2023,46(24): 164-171.
- [21] 曹建芳,彭存赫,陈志强,等. 基于改进 ResNet 深度学习的古代壁画分类方法[J]. *电子测量技术*, 2025, 48(1):186-196.
- CAO J F, PENG C H, CHEN ZH Q, et al. Ancient mural classification method based on improved ResNet deep learning[J]. *Electronic Measurement Technology*, 2025,48(1): 186-196.
- [22] MYLONAKIS C M, VELANAS P, LAZARIDIS P I, et al. Deep learning framework using spatial attention mechanisms for adaptable angle estimation across diverse array configurations[J]. *Technologies*, 2025, 13(2): 46.
- [23] 薛钟毫,姜金刚,孙健鹏,等. 基于多尺度卷积和选择性核双注意力机制的半监督全景 X 射线图像龋齿分割[J]. *仪器仪表学报*, 2025,46(6):241-250.
- XUE ZH H, JIANG J G, SUN J P, et al. Semi-supervised panoramic X-ray image caries segmentation based on multi-scale convolution and selective kernel dual attention mechanism[J]. *Chinese Journal of Scientific Instrument*, 2025,46(6): 241-250.
- [24] 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 in logarithmic spiral array [J]. *Journal of Electronic Measurement and Instrumentation*, 2023,37(2): 220-227.
- [25] 周先春,吕梦楠,芮旸,等. 基于注意力机制的双卷积图像去噪网络[J]. *电子测量与仪器学报*, 2025,39(2): 60-71.
- ZHOU X CH, LYU M N, RUI Y, et al. Double convolution image denoising network based on attention mechanism[J]. *Journal of Electronic Measurement and Instrumentation*, 2025,39(2): 60-71.

## 作者简介

**熊伟华**, 硕士研究生, 主要研究方向为基于深度学习的 DOA 估计。

E-mail: 3139163262@qq.com

**章勇**(通信作者), 博士, 教授, 主要研究方向为高压设备局部放电监测、射频通信、深度学习等。

E-mail: yongzhang@ecut.edu.cn

**张雪梅**, 硕士研究生, 主要研究方向为电力设备局部放电模式识别。

E-mail: 2392989897@qq.com

**李良尧**, 硕士研究生, 主要研究方向为局部放电模式识别系统开发。

E-mail: 1037944803@qq.com