非高斯干扰下基于神经网络的到达方向估计

S. Feintuch , J. Tabrikian , *IEEE* 会士，I. Bilik，*IEEE* 高级会员，以及 H. Permuter，*IEEE* 高级会员 *E*

arXiv:2301.02856v2 [eess.SP] 5 Jul 2023

摘要—**本文研究了非高斯、重尾和空间有色干扰下的到达方向（DOA）估计问题。传统上，通常假设干扰服从高斯分布且为空间白噪声。然而，在实际应用中，这一假设并不总是成立，导致到达方向估计性能下降。在非高斯和空间有色干扰下进行最大似然到达方向估计，计算复杂度很高，因而不实用。因此，本文提出了一种基于神经网络（NN）的到达方向估计方法，用于在非高斯空间有色干扰下、信源数量先验未知的多信源场景中的空间谱估计。该方法使用单个神经网络实例，同时进行信源数估计和到达方向估计。仿真结果表明，在低信干比、样本支持度较小，以及信源到达方向与空间有色干扰之间的角度间隔较小的情况下，所提方法在分辨概率、估计精度和信号源数目估计精度方面均显著优于传统方法和基于神经网络的方法。**

索引词—**阵列处理、到达方向估计、信源数估计、空间有色干扰、非高斯干扰、神经网络、深度学习、机器学习、最小方差无失真响应、最小描述长度、赤池信息准则、雷达。**

I. 引言

在雷达、声呐、超声波、无线通信和医学成像等多种应用中，都需要利用传感器阵列进行到达方向估计 [1]。在实际应用中，传感器阵列接收到的信号是感兴趣信号源发出的信号、干扰和接收机热噪声的叠加。在雷达中，接收信号由目标回波、杂波和热噪声组成。在多种场景下，雷达杂波服从空间有色、重尾非高斯分布 [2], ，这会显著降低传统估计器的性能。

最小方差无失真响应（MVDR） [3], 是用于到达方向估计的传统自适应波束形成方法。MVDR 估计空间谱，并通过在预定义网格上进行一维峰值搜索来获得信源到达方向。采用旋转不变技术的信号参数估计（ESPIRIT） [4], 、多重信号分类（MUSIC） [5], 和根MUSIC（R-MUSIC） [6]是另外几种广泛使用的到达方向估计方法。这些方法涉及接收信号自相关矩阵处理，通常通过样本自相关矩阵估计 [3]–[6]来完成。然而，在小样本支持度或非高斯场景下，样本自相关矩阵估计器的性能会下降。此外，这些方法仅使用二阶统计量，而忽略了非高斯分布干扰中的高阶统计量。另外，ESPRIT、MUSIC 和 R-MUSIC 方法需要先验了解信源（或目标）的数量，这限制了它们的实际应用。

非高斯干扰环境下的到达方向估计问题在实际应用中具有重要意义。针对非高斯干扰环境下的到达方向估计，最大似然估计（MLE）没有闭式解析解 [7], [8]。文献中已对多种基于模型的波达方向估计方法进行了深入研究 [7]–[18]。

文献中已研究了稳健的基于协方差矩阵的波达方向估计和信源数目估计方法。对于服从复椭圆对称（CES）分布的数据， [9] 中的作者证明，基于散布矩阵的波束形成器具有一致性，并推导了到达方向估计的半参数下界和 Slepian-Bangs 公式 [10]。 [11], 提出了一种基于广义协方差（GC）的方法，用于脉冲型α稳定噪声场景下的协方差矩阵估计，并将其用于 MUSIC 到达方向估计。然而，这些方法针对的是特定分布族，例如复椭圆对称分布或α稳定分布，因此在模型失配时存在局限。 [12],提出了一种基于概率测度变换（MT）的协方差矩阵估计器，用于基于 MUSIC 的到达方向估计和基于最小描述长度（MDL）的信源数估计。该基于 MT 的协方差估计器也被用于稳健的 MVDR 波束形成器 [13]。这些方法通常通过设定一个参数来权衡稳健性和性能。

文献 [7]研究了在确定性未知（条件）信源模型下，存在空间白噪声干扰与高斯分布噪声混合的 K 分布噪声时的到达方向估计问题。文献 [14], [15]推导了一种基于最大似然估计的迭代方法，用于估计干扰分布参数的条件似然与联合似然。文献 [16]进一步将该方法扩展至边缘似然函数。然而，由于需要进行数值积分计算，且涉及针对 M 个目标的 $2M$ 维网格搜索，该方法的计算复杂度较高 [8]。因此，文献 [8] 提出了一种基于核最小误差熵的自适应估计器，以及一种用于降低估计器计算复杂度的新准则。针对条件模型，提出了一种基于部分松弛的期望最大化（EM）到达方向估计算法

Stefan Feintuch、Joseph Tabrikian、Igal Bilik 和 Haim H. Permuter 均任职于以色列贝尔谢巴内盖夫本-古里安大学电气与计算机工程学院。（电子邮件：stefanfe@post.bgu.ac.il、joseph@bgu.ac.il、bilik@bgu.ac.il、haimp@bgu.ac.il）。本研究部分由以色列科学基金会资助，基金项目编号为 2666/19 和 1895/21。

假设，见 [17]。文献 [18], 提出了一种稀疏贝叶斯学习（SBL）方法，用于剔除脉冲干扰和空间白噪声干扰中的离群值。该基于期望最大化的方法无需先验信源数量知识，并且能够分辨高度相关和相干信源。然而，这些基于模型的到达方向估计方法均未考虑先验未知信源数量和空间有色干扰，因此在实际应用中受到限制。尽管可以使用最小描述长度（MDL）和赤池信息准则（AIC）等信源数目估计方法 [19] ，但这些方法假设信号具有高斯性，因此在非高斯场景下可能不准确。

近年来，深度学习和机器学习方法已应用于雷达信号处理。文献中提出了三种基于神经网络的波达方向估计方法 [20]。第一种方法假设信源数量先验已知，并使用神经网络输出到达方向估计值向量 [21]–[27]。第二种方法不假设信源数量先验已知，而是使用神经网络进行信源数估计 [25]–[31]。第三种方法使用神经网络估计预定义角度网格上各个到达方向的信源存在概率，并通过峰值搜索获得信源到达方向 [32]–[41]。然而，这些方法都未解决非高斯和空间有色干扰问题 [20]–[41]。

针对非高斯和/或空间有色干扰的情况，已有研究采用基于机器学习的方法进行处理。对于大规模多输入多输出认知雷达，文献 [42]提出了一种基于强化学习的方法，用于在重尾空间有色干扰下进行多目标检测。在 [43], 中，作者采用 CNN 架构处理非高斯空间有色干扰下的 MIMO雷达目标检测，并根据一种新型损失函数对该架构进行优化。文献 [44] 和 [45] 分别提出了径向基函数神经网络和卷积神经网络（CNN）架构，用于非高斯脉冲噪声下的到达方向估计。在 [46], 中，提出了一种基于 CNN 的架构，其中包含去噪神经网络、信源数目估计神经网络和到达方向估计子神经网络。然而， [44]–[46] 考虑的是空间白噪声，因此在存在空间有色干扰的场景下性能并非最优。

在 [47], 中，本文提出了一种新颖的基于神经网络的方法，用于在距离-多普勒域中，在慢时间相关且呈重尾分布的杂波下进行雷达目标检测，且不进行任何空间处理。本研究将 [47] 拓展至阵列处理领域，采用类似的基于神经网络的方法，并以信号源到达方向估计和信源数估计的性能准则为依据。具体而言，我们研究了在信源数量先验未知的情况下，存在非高斯、重尾、空间有色干扰，且信干比较低、样本量较小的阵列处理问题。本文的贡献包括:

1) 提出了一种新颖的基于神经网络的处理机制，用于非高斯空间有色干扰下的阵列处理。所提出的神经网络架构利用了接收快拍集合中的信息结构。

2) 所提出的神经网络经过优化，可输出经干扰抑制的空间谱，并用于非高斯空间有色干扰下信源数估计与信源到达方向估计。

在存在非高斯空间有色干扰的场景中，就分辨概率和估计精度而言，所提出的方法优于传统自适应波束形成，并可与简单的基于神经网络的方法相媲美。此外，在以非高斯空间有色干扰为特征的场景中，所提出的方法优于传统信源数估计技术。

本文全文采用以下符号。罗马粗体小写和大写字母分别表示向量和矩阵，斜体字母表示标量。$\mathbf{I}_N$ 是大小为 $N \times N$ 的单位矩阵，而 $\mathbf{1}_N$是长度为 N 且各元素均为 1 的列向量。 $\mathbb{E}(\cdot)$、$(\cdot)^T$和$(\cdot)^H$ 分别表示期望、转置和厄米特转置算子。Vec(·)、diag(·)和 $|\cdot|$ 分别表示向量化、对角化和绝对值算子。 $[\mathbf{a}]_n$ 和 $[\mathbf{A}]_{n,m}$ 分别是向量$\mathbf{a}$ 和矩阵$\mathbf{A}$的第n个和第 n,m个元素。

本文其余部分安排如下。第二节II陈述所研究的问题。第三节III 介绍所提出的基于神经网络的到达方向估计方法。第四节IV通过仿真评估所提出的方法。第五节V总结全文。

II. 问题定义

本文研究利用由 L 个接收阵元组成的阵列，对具有到达方向 $\mathbf{\Theta} = \{\theta_1, \ldots, \theta_M\}$ 的 M 个不同且未知信源进行到达方向估计的问题。测量值包含 K 个空间快拍， $\{\mathbf{x}_k\}_{k=1}^K$:

$$\begin{aligned}\mathbf{x}_k &= \mathbf{A}\left(\mathbf{\Theta}\right)\mathbf{s}_k + \sigma_c\mathbf{c}_k + \mathbf{n}_k\ , \\ &= \sum_{m=1}^{M}\mathbf{a}\left(\theta_m\right)s_{k,m} + \sigma_c\mathbf{c}_k + \mathbf{n}_k\ ,\ k = 1, \ldots, K\ ,\end{aligned} \tag{1}$$

其中，$\mathrm{A}\left(\mathbf{\Theta}\right) = \left[\mathrm{a}\left(\theta_1\right)\cdots\mathrm{a}\left(\theta_M\right)\right]$, $\mathrm{a}\left(\theta_m\right) \in \mathbb{C}^L$ 表示方向为 θ_m 的信号源的导向矢量，$\mathrm{s}_k \triangleq \left[s_{k,1} \quad \cdots \quad s_{k,M}\right]^T$ 是信源信号向量。我们假设采用非条件模型 [48],，其中 $\{\mathrm{s}_k\} \overset{i.i.d.}{\sim} \mathcal{CN}\left(\mathbf{0}_M,\ \mathrm{diag}\left(\sigma_1^2,\ \ldots,\sigma_M^2\right)\right)$ 在脉冲之间时间不相关。假设各目标在空间上不同。接收机热噪声记为 n_k，并假设其服从复高斯分布 $\{\mathrm{n}_k\} \overset{i.i.d.}{\sim} \mathcal{CN}\left(\mathbf{0}_L, \sigma_n^2\mathbf{I}_L\right)$。重尾非高斯且空间有色的干扰由干扰幅度 σ_c 和干扰分量 $\mathrm{c}_k \in \mathbb{C}^L$ 建模。所考虑的复合高斯分布干扰 $\{\mathrm{c}_k\} \overset{i.i.d.}{\sim} \mathcal{K}\left(\nu, \theta_c\right)$ 表示一种在未知方向 θ_c 周围具有角扩展的非高斯干扰，使得 $\mathrm{c} \sim \mathcal{K}\left(\nu, \theta_c\right)$ 意味着

$$\begin{aligned}&\mathbf{c} = \sqrt{\tau}\mathbf{z}\ , \\ &\tau \perp\!\!\!\perp \mathbf{z},\ \tau \sim \Gamma\left(\nu, \nu\right),\ \mathbf{z} \sim \mathcal{CN}\left(\mathbf{0}_L, \mathbf{M}_{\theta_c}\right)\ .\end{aligned} \tag{2}$$

文献中通常使用复合高斯统计模型来建模重尾非高斯

干扰 [7], [8], [14], [16], [43], [49]。纹理分量，$\tau \in \mathbb{R}_+$，决定了重尾行为，其特征由 ν。斑点分量，$\mathbf{z} \in \mathbb{C}^L$，决定了干扰的空间分布，其特征由协方差矩阵$\mathbf{M}_{\theta_c}$描述。干扰的空间协方差矩阵满足：

$$\mathbb{E}\left[\sigma_c^2 \mathbf{c}\mathbf{c}^H\right] = \sigma_c^2 \mathbb{E}[\tau]\,\mathbb{E}\left[\mathbf{z}\mathbf{z}^H\right] = \sigma_c^2 \mathbf{M}_{\theta_c}\ , \tag{3}$$

其中$\mathbf{M}_{\theta_c}$ 可建模为 [14]–[16], [43], [49]:

$$[\mathbf{M}_{\theta_c}]_{m,l} = \rho^{|m-l|} e^{j(m-l)\pi \sin\theta_c}\ . \tag{4}$$

(3) 和 (4) 中的模型表示空间干扰，其特征由 ρ 描述，其分布围绕干扰到达方向θ_c展开。

III. 所提出的基于 DAFC 的神经网络

下文将在第III-A 和 III-B小节介绍数据预处理和所提出的基于神经网络的处理机制。第III-C 和 III-D小节分别详细介绍所提出的神经网络架构和损失函数。

所提出的方法与一种用于距离-多普勒域线性调频（LFM）雷达目标检测的神经网络架构相似 [47]。本文提出的架构采用了 [47]中介绍的维度交替全连接（DAFC）机制。然而，由于本文研究的是不同问题，我们通过实验发现，第III-A、III-C和 III-D小节所述的预处理、神经网络架构和损失函数分别能够取得更好的结果。

A. 预处理

输入矩阵 $\mathbf{X} \in \mathbb{C}^{L\times K}$ 由以下快拍集合构成： K 式（1）， $\{\mathbf{x}_k\}$:

$$\mathbf{X} = \begin{bmatrix}\mathbf{x}_1 & \mathbf{x}_2 & \cdots & \mathbf{x}_K\end{bmatrix}\ , \tag{5}$$

其中，$\mathbf{X}$ 的第 k 列包含第 k 个快拍。$\mathbf{X}$ 各列之间的差异由信源信号 $\mathbf{s}_k$、干扰信号 $\mathbf{c}_k$和热噪声 $\mathbf{n}_k$的统计特性所引起。因此，$\mathbf{X}$ 中的每一列都可视为一个复数“特征”向量，其中包含到达方向估计所需的关键信息。$\mathbf{X}$ 中的列集合可视为该特征的“实现”。

复数值矩阵$\mathbf{X}$被转换为实数值表示，以供基于神经网络的处理使用。为与 [47], 保持一致，我们对输入矩阵应用转置算子，使快拍按行堆叠。预处理的输出记为$\mathbf{Z}_0 \in \mathbb{C}^{K\times 2L}$，其形式如下：

$$\mathbf{Z}_0 = \left[\mathrm{Re}\{\mathbf{X}^T\},\ \mathrm{Im}\{\mathbf{X}^T\}\right]\ . \tag{6}$$

B. 维度交替全连接

引入 DAFC 模块，用于以类似于第 II [47]节模型的形式处理测量值。图 1以示意图形式展示了 DAFC 的工作机制。

对于任意维度 D_1, D_2, D_3，将通用全连接（FC）层应用于给定矩阵的每一行时，给定矩阵 $\mathbf{Z} \in \mathbb{R}^{D_1\times D_2}$ 可表示为变换$\mathcal{F}(\cdot)$:

$$\begin{aligned}&\mathcal{F}: \mathbb{R}^{D_1\times D_2} \to \mathbb{R}^{D_1\times D_3}\ ,\\ &\mathcal{F}(\mathbf{Z}) \triangleq h\left(\mathbf{Z}\mathbf{W} + \mathbf{1}_{D_1}\mathbf{b}^T\right)\ .\end{aligned} \tag{7}$$

该矩阵到矩阵的变换由“可学习”的权重矩阵$\mathbf{W} \in \mathbb{R}^{D_2\times D_3}$、偏置向量$\mathbf{b} \in \mathbb{R}^{D_3}$以及标量逐元素激活函数 $h(\cdot)$ 表征。

设 $\mathcal{F}_r(\cdot)$ 和 $\mathcal{F}_c(\cdot)$ 是来自式 $\mathcal{F}(\cdot)$ （7）的两个彼此独立且不一定相同的实例，而$\mathbf{Z}_{in}$ 是任意输入矩阵。DAFC 机制由以下操作构成：

维度交替全连接

- **Input:** $\mathbf{Z}_{in} \in \mathbb{R}^{H\times W}$
  $\mathcal{F}_r: \mathbb{R}^{H\times W} \to \mathbb{R}^{H\times W'}$
  $\mathcal{F}_c: \mathbb{R}^{W'\times H} \to \mathbb{R}^{W'\times H'}$
  1) 对$\mathbf{Z}_{in}$的每一行应用一个全连接层：
  $$\mathbf{Z}_r = \mathcal{F}_r(\mathbf{Z}_{in})$$
  2) 对$\mathbf{Z}_r$的每一列应用一个全连接层：
  $$\mathbf{Z}_c = \mathcal{F}_c\left(\mathbf{Z}_r^T\right)$$
  3) 转置以保持方向：
  $$\mathbf{Z}_{out} = \mathbf{Z}_c^T$$
- **输出：** $\mathbf{Z}_{out} \triangleq \mathcal{S}(\mathbf{Z}) \in \mathbb{R}^{H'\times W'}$

下面将详细介绍三项 DAFC设计原则。

1）结构化变换

第一个DAFC模块的输入是预处理后的，$\mathbf{Z}_0$,如式（6）所示。因此，第一个DAFC模块的第一个全连接层 $\mathcal{F}_r$能够从$\mathbf{Z}_0$中的每一行提取空间相关特征。第一个DAFC模块的第二个全连接层 $\mathcal{F}_c$则在经过变换的各行之间引入交互。这意味着：a） $\mathcal{F}_r$ 能够通过将每个预处理后的快照（$\mathbf{Z}_0$ 的每一行）变换至高维特征空间，完成“空间特征”提取；b） $\mathcal{F}_c$ 能够对从每个快照中提取的特征（($\mathbf{Z}_0$)的各列）进行非线性变换。通过这种方式，DAFC同时利用了空间信息和统计信息。因此，将DAFC机制融入神经网络后，有助于估计信源到达方向并抑制干扰。

2）可学习参数降维

传统的到达方向估计将输入数据视为测量向量（快拍 $\{\mathbf{x}_k\}$）的集合，并以矩阵形式表示。使用神经网络处理输入数据的一种直接方法是对其进行重塑，并通过基于全连接层的架构进行处理。这样，输出层中的每个神经元都会与输入中的每个神经元交互。另一方面，DAFC模块通过结构化变换来变换数据，与直接的基于全连接层的方法相比，可大幅减少可学习参数的数量。

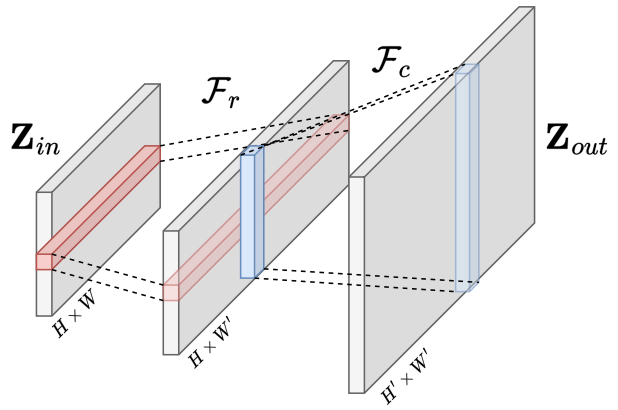


图 1：DAFC 机制概念。$\mathbf{Z}_{in}$ 中维度为 W 的每一行（以红色表示）都通过 $\mathcal{F}_r$ 变换为中间矩阵中维度为 W' 的一行（以半透明红色表示）。接着，中间矩阵中维度为 H 的每一列（以蓝色表示）都通过 $\mathcal{F}_c$ 变换为 $\mathbf{Z}_{out}$ 中维度为 H' 的一列（以半透明蓝色表示）。

在以下典型案例中可以观察到这种参数数量的减少。考虑一个输入矩阵 $\mathbf{Z}_1 \in \mathbb{R}^{D_1 \times D_1}$，它被变换为输出矩阵 $\mathbf{Z}_2 \in \mathbb{R}^{D_2 \times D_2}$。基于全连接层的方法和所提出的基于 DAFC 的方法所需的可学习参数数量分别为 $\mathcal{O}\left(D_1^2 D_2^2\right)$ 和 $\mathcal{O}(D_1 D_2)$ 量级。请注意，与直接的基于全连接层的方法的复杂度呈二次增长相比，基于 DAFC 的变换复杂度随可学习参数数量呈线性增长。

减少可学习参数的维度有两方面作用。首先，传统的神经网络优化是基于梯度的 [50]。因此，大幅降低可学习参数的维度，可以减少可优化参数空间中的自由度，并提高基于梯度的学习算法的收敛速度。其次，降低可学习参数的维度可以理解为增强神经网络模型的“归纳偏置” [51]，，这通常有助于提高神经网络的统计效率和泛化能力，从而降低神经网络对训练数据过拟合的倾向。

3) 非线性

与直接的 FC 方法相比，所提出的 DAFC 增加了一个非线性维度。直接的矩阵到矩阵方法包含输出矩阵中的每个神经元与输入矩阵中的每个神经元之间的相互作用，随后进行逐元素非线性激活函数运算。另一方面，所提出的 DAFC 在 $\mathcal{F}_r$ 和 $\mathcal{F}_c$ 中包含两个非线性维度。尽管作为 $\mathcal{F}_r$ 和 $\mathcal{F}_c$的一部分所应用的权重矩阵维度低于直接方法中使用的权重矩阵，但额外的非线性维度可以提升神经网络的容量 [50]。因此，采用所提出 DAFC 的神经网络架构能够学习对输入数据进行更抽象、更丰富的变换。

C. 神经网络架构

连续的到达方向空间被离散化为一个 d 维网格：$\boldsymbol{\phi} = \begin{bmatrix}\phi_1 & \phi_2 & \cdots & \phi_d\end{bmatrix}^T$。这意味着整个视场 (FOV) 被划分为 d 个到达方向，$\{\phi_i\}_{i=1}^d$，其数量由所选网格分辨率决定，$\Delta\phi \triangleq \phi_{i+1} - \phi_i$。所提出的神经网络旨在表示从输入快拍集合 $\{\mathbf{x}_k\}$（见式（1））到各到达方向上存在信号源的概率 $\{\phi_i\}_{i=1}^d$的映射。所提出的神经网络架构表示如下：

$$\begin{aligned}\mathbf{Z}_0 &= \mathcal{P}(\mathbf{X}) \ , \\ \mathbf{z}_{\text{vec}} &= \text{Vec}\left(\mathcal{S}_6\left(\ldots \mathcal{S}_1\left(\mathbf{Z}_0\right)\right)\right) \ , \\ \hat{\mathbf{y}} &= \mathcal{G}_3\left(\mathcal{G}_2\left(\mathcal{G}_1\left(\mathbf{z}_{\text{vec}}\right)\right)\right) \ ,\end{aligned} \tag{8}$$

其中 $\mathbf{Z}_0$ 是预处理过程的输出，记为 $\mathcal{P}(\cdot)$，详见第 III-A 节；而 $\mathbf{X}$ 是式（5）中的输入矩阵。

在下一阶段，使用六个维度各异的 DAFC 实例（表示为$\mathcal{S}_1(\cdot)\ldots,\mathcal{S}_6(\cdot)$），通过双曲正切激活进行行变换（$\mathcal{F}_r$ 见第 III-B 节），并通过 ReLU 激活进行列变换（$\mathcal{F}_c$ 见第 III-B 节），以生成向量化信号 $\mathbf{z}_{\text{vec}}$。我们的实验表明，这种行、列激活函数配置可获得最佳性能。在最后阶段，信号 $\mathbf{z}_{\text{vec}}$由三个全连接层处理，其中前两层使用双曲正切激活，最后一层（输出层）的大小等于 DOA 网格维度 d，并使用 Sigmoid 激活函数输出 $\hat{\mathbf{y}} \in [0,1]^d$。因此，$\{[\hat{\mathbf{y}}]_i\}_{i=1}^d$ 表示在 $\{\phi_i\}_{i=1}^d$处存在信号源的估计概率。表 I 和图 2 总结了所提出的基于神经网络的方法的参数和架构。

通过峰值搜索 并应用 0.5 阈值，从空间谱中提取估计的信源到达方向：

$$\begin{aligned}\{i_1,\ldots,i_{\hat{N}}\} &= \textit{peak_search}\left(\{[\hat{\mathbf{y}}]_i\}_{i=1}^d\right) \\ \hat{\boldsymbol{\Theta}} &= \left\{\phi_{i_n} : [\hat{\mathbf{y}}]_{i_n} > 0.5\right\}_{n=1}^{\hat{N}} \ .\end{aligned} \tag{9}$$

也就是说，估计的到达方向集合 $\hat{\boldsymbol{\Theta}}$ 由对应于 $\hat{\mathbf{y}}$ 中超过 0.5 阈值的峰值的网格点组成。超过此阈值的峰值数量用于信源数估计，因此，所提出的神经网络也可用作信源数估计方法。

所提出的神经网络架构中隐藏层的维度在前几层逐渐扩展，随后逐渐缩减。这一趋势与 [47] 中展示的神经网络架构相似，并体现于基于 DAFC 和基于全连接层的处理阶段。这种扩展—缩减结构可以这样解释：a）神经网络前期阶段需要通过将输入数据映射到高维表示，学习具有表现力且有意义的变换；b）后期阶段需要从前期映射中提取显著特征，因此维度受到限制。此外，后期阶段与输出向量相邻，因此其维度需要与输出向量相近。

D. 损失函数

用于监督学习过程的标签，$\mathbf{y} \in \{0,1\}^d$，定义为一个稀疏二进制向量，在数值为 1 时，

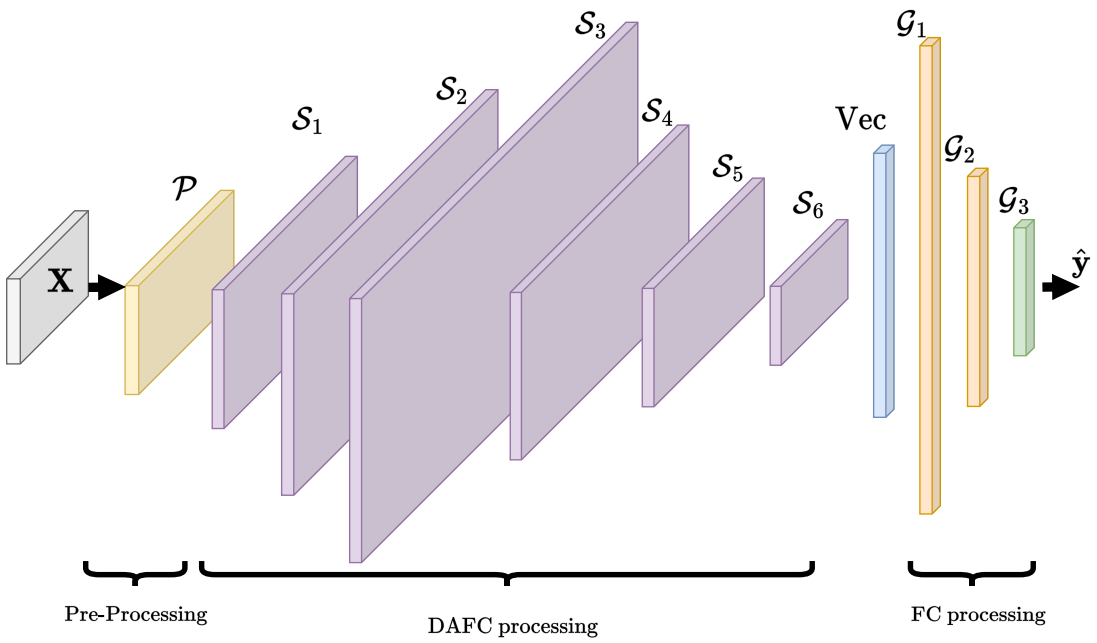


图 2：所提出的神经网络架构。预处理 $\mathcal{P}$ 在第 III-A 节中进行了说明，并以黄色显示。紫色矩阵表示 DAFC 模块的串联，详见第 III-B 节。蓝色向量表示对最后一个 DAFC 输出进行向量化后的结果，橙色向量表示采用双曲正切激活函数的全连接层。最后一个绿色向量是最后一个全连接层的输出，该层使用逻辑斯蒂函数作为激活函数，并生成估计空间谱 $\hat{}\mathbf{y}$。

算子	输出维度	激活函数	# 参数
$\mathcal{P}$	$K \times 2L$	-	-
$\mathcal{S}_1$	64×256	双曲正切-ReLu	9,536
$\mathcal{S}_2$	128×512	双曲正切-ReLu	139,904
$\mathcal{S}_3$	256×1024	双曲正切-ReLu	558,336
$\mathcal{S}_4$	64×512	双曲正切-ReLu	541,248
$\mathcal{S}_5$	16×256	双曲正切-ReLu	132,368
$\mathcal{S}_6$	4×128	双曲正切-ReLu	32,964
vec	512	-	-
$\mathcal{G}_1$	1024	tanh	525,312
$\mathcal{G}_2$	256	tanh	262,400
$\mathcal{G}_3$	d	逻辑斯蒂函数	31,097

表 I：$K = 16$、 $L = 16$、 $d = 121$的所提出神经网络架构规格。“双曲正切-ReLU”激活函数表示每个 DAFC 模块的 $\mathcal{F}_r$ 中采用双曲正切， $\mathcal{F}_c$ 中采用 ReLU。可学习参数总数为 $2,233,165$。

对应于信源到达方向的网格点取值为 1，否则为 0。实际上，$\boldsymbol{\Theta}$ 中的到达方向并不精确对应网格点。因此，对于$\boldsymbol{\Theta}$中的每个到达方向，选择 $\{\phi_i\}_{i=1}^{d}$ 中最近的网格点作为标签中的代表网格点。每个训练样本由输入-标签对 $(\mathbf{X},\mathbf{y})$确定。使用式（8）中的神经网络前馈传播， $\mathbf{X}$ 用于生成输出空间谱 $\hat{}\mathbf{y}$，该谱被视为估计标签。

损失函数 $\mathcal{L}$是对每个网格点计算的二元交叉熵（BCE）损失的加权平均值：

$$\mathcal{L}\left(\mathbf{y},\hat{\mathbf{y}},t\right) = \frac{1}{d}\sum_{i=1}^{d} w_i^{(t)} \mathrm{BCE}\left([\mathbf{y}]_i,[\hat{\mathbf{y}}]_i\right), \tag{10}$$

$$\mathrm{BCE}\left(y,\hat{y}\right) = -y\log\left(\hat{y}\right) - (1-y)\log\left(1-\hat{y}\right),$$

其中， $w_i^{(t)}$ 表示 i网格点在第 t个训练轮次的损失权重。对于每个网格点计算等权重 BCE（式（$w_i^{(t)} = 1$ （10））的损失值，当信号源/干扰的估计概率出现较大误差时，并不会显著增大，这是由于标签$\mathbf{y}$具有稀疏性。这会迫使神经网络收敛到容易“漏检”信源的次优解。因此，引入损失权重，以便将惩罚“集中”在信号源/干扰网格点上。

第 i 个网格点的损失权重 $w_i^{(t)}$ 由对应标签条目 $[\mathbf{y}]_i$ 中是否存在信号源或干扰决定。该关系由依赖于训练轮次和标签的因子 $e_0^{(t)}, e_1^{(t)}$ 定义，如下所示：

$$w_i^{(t)} = \begin{cases} 1/e_1^{(t)}, & \text{if } \phi_i \text{ contains source or interference} \\ 1/e_0^{(t)}, & \text{else} \end{cases}. \tag{11}$$

对于 $t=0$，因子 $e_1^{(0)}$ 由训练集中包含信号源或干扰的标签网格点占标签网格点总数的比例决定，而 $e_0^{(0)}$ 是相应的补数。在后续训练轮次中，这些因子会根据预定义的计划进行更新，类似于预定义的学习率计划。训练期间，损失权重每隔 Δt 个训练轮次更新 N_w 次。更新值通过按照以下衰减规则更新 $e_0^{(t)}, e_1^{(t)}$ 来确定：

$$e_q^{(t)} = (1-\beta^{(l)})e_q^{(l\Delta t)} + \beta^{(l)},\ l\Delta t \le t < (l+1)\Delta t \quad (12)$$
$$q=0,1,\ l=1,\ldots,N_w,$$

其中 l 是损失权重更新迭代，$\{\beta^{(l)}\}_{l=1}^{N_w}$表示所采用的损失权重更新因子，$0 \le \beta^{(l)} \le 1$。注意，对于 $N_w\Delta t \le t$，权重因子在 $e^{(N_w\Delta t)}$ 训练阶段的其余时间内保持不变。请注意，随着 $\beta^{(l)} \to 1$，相应的损失权重将趋于在各网格点之间均匀分布，即 $e_1^{(t)} \approx e_0^{(t)}$。在这种情况下，对于包含信号源/干扰的网格点，其错误估计的概率与不包含信号源/干扰的网格点具有相同的权重。另一方面，随着 $\beta^{(l)} \to 0$，相应因子将保持 $e_1^{(t)} \ll e_0^{(t)}$，从而使包含信号源/干扰的网格点对损失值的贡献显著增大。（12）中的规则使训练过程中能够实现“关注重点的转移”。也就是说，在训练初期 $\beta^{(l)} \to 0$，这会增大估计标签中包含信号源/干扰区域的权重 $\hat{\mathbf{y}}$（即估计的空间谱），使神经网络专注于正确估计信号源/干扰。在训练后期，$\beta^{(l)}$ 逐步增大，从而减弱训练初期对信号源/干扰的关注。因此，可以减少在不包含信号源/干扰的区域中错误估计出的信号源（即“虚警”）。

IV. 性能评估

本节评估所提出的基于DAFC的神经网络方法的性能，并将其与小节IV-A1中总结的传统方法进行比较。所有考虑场景的数据均使用第II节中的测量模型进行仿真。

A. 设置与训练

本文考虑一个阵元间距为半波长的均匀线阵（ULA）L。每个仿真实例由一个输入-标签对($\mathbf{X}$，$\mathbf{y}$)组成，其中输入$\mathbf{X}$ 定义于式（5）中，标签$\mathbf{y}$ 定义于第III-D节。仿真配置详见表II。本文使用一个**神经网络实例**评估所提方法的性能。因此，对于各种信干比（SIR）、信噪比（SNR）、干扰噪声比（INR）、到达方向、干扰分布以及信源数量，均使用同一个神经网络模型进行联合到达方向估计和信源数估计。所有实验均采用以下第 m个信源的定义：

$$\text{INR} = \frac{\mathbb{E}\left[\|\mathbf{c}\|^2\right]}{\mathbb{E}\left[\|\mathbf{n}\|^2\right]} = \sigma_c^2/\sigma_n^2\ , \quad (13)$$

$$\text{SNR}_m = \frac{\mathbb{E}\left[\|\mathbf{a}(\theta_m)s_m\|^2\right]}{\mathbb{E}\left[\|\mathbf{n}\|^2\right]} = \sigma_m^2/\sigma_n^2\ , \quad (14)$$

$$\text{SIR}_m = \frac{\mathbb{E}\left[\|\mathbf{a}(\theta_m)s_m\|^2\right]}{\mathbb{E}\left[\|\mathbf{c}\|^2\right]} = \sigma_m^2/\sigma_c^2\ . \quad (15)$$

所有评估架构的神经网络优化均采用式（10）中的损失函数和 Adam 优化器 [52]，学习率为 10^{-3}，并使用平台期学习率调度器，衰减率为0。905。损失权重更新因子集合 $\{\beta^{(l)}\}_{l=1}^{N_w}$在式（12中选为介于 10^{-5} 和 10^{-2} 之间的等间距对数刻度，取 $N_w=6$，即 $\{10^{-5}, 7.25\cdot10^{-5}, 5.25\cdot10^{-4}, 3.8\cdot10^{-3}, 2.78\cdot10^{-2}, 0.2\}$。批量大小设为512，训练轮数为500，并根据最后200 轮训练进行提前停止。

符号说明	描述	数值
M_{max}	最大数量 of 信源	4
L	传感器数量	16
K	快拍数	16
d	角度网格维度	121
$\Delta\phi$	角度网格分辨率	1°
FOV	视场	$[-60°, 60°]$
σ_n^2	热噪声功率	1

表 II：仿真配置。

1）到达方向估计方法：本小节简要概述了传统的到达方向估计方法。本文将所提出方法的性能与传统的最小方差无失真响应、卷积神经网络和基于全连接网络的神经网络进行比较。所有基于神经网络的方法均采用了相近数量的层和可学习参数。此外，基于全连接网络的神经网络和卷积神经网络使用相同的学习算法和配置进行优化。

(a) 传统 *Ada* p自适应波束f形成 g最小方差无失真响应 [3]估计器基于自适应波束形成；在未知高斯干扰 [53]存在的情况下，它是最大似然估计器。最小方差无失真响应通过在 MVDR 谱上搜索峰值来估计到达方向：

$$P_{MVDR}(\phi) = \frac{1}{\mathbf{a}^H(\phi)\,\hat{\mathbf{R}}_x^{-1}\mathbf{a}(\phi)}\ , \quad (16)$$

其中 $\hat{\mathbf{R}}_x = \frac{1}{K}\sum_{k=1}^{K}\mathbf{x}_k\mathbf{x}_k^H$是样本协方差矩阵估计器。请注意，MVDR 谱仅利用接收信号 $\mathbf{x}_k$的二阶统计量。对于仅含高斯干扰（即，$\mathbf{c}_k = 0$ 在（1）中），二阶统计量包含全部统计信息。然而，对于非高斯干扰，则需要利用高阶统计量中的信息。

(*b*) 卷积神经网络架构

我们考虑一种基于卷积神经网络的到达方向估计方法，其卷积神经网络架构与 [38] 中给出的架构相似。维度为 $L\times L\times 3$ˆ 的卷积神经网络输入由$\mathbf{R}_x$ 的实部、虚部和相位部分组成。该卷积神经网络架构由连续的 4 个卷积神经网络块构成，

每个块均包含一个卷积层、一个批归一化层和一个 ReLU 激活函数。卷积层包含 $[128, 256, 256, 128]$ 个卷积核。第一个块使用卷积核尺寸3×3，其余三个块使用 2×2。与 [38]类似， 2×2 第一个块使用步幅 1×1，其余三个块使用。接下来，使用一个展平层将隐藏张量向量化，并使用3 个维度分别为1024、512、256 的全连接层，配以 ReLU 激活和 30%的 Dropout。最后，输出层与第 III-C 小节所述的基于 DAFC 的神经网络相同III-C。所考虑的损失函数与式（10）中提出的基于 DAFC 的方法相同。所考虑的 CNN 架构包含 3,315, 449 个可训练参数。请注意，基于 CNN 的架构利用了样本协方差矩阵中的信息，因此仅限于使用二阶统计量。

(c) 全连接架构

如第III-B小节所述，我们实现了一种直接的基于全连接层的架构。数据矩阵 $\mathbf{X}$被向量化，并将数值的实部和虚部拼接起来，得到一个 $2KL$ 维输入向量。选取的隐藏层大小为： $[512, 512, 1024, 1024, 512, 256]$ 其中每个隐藏层之后都接一个 tanh 激活函数。输出层与第III-C小节详述的基于 DAFC 的神经网络方法中的输出层相同。所考虑的损失函数为（10），基于全连接网络的神经网络含有 2,787,449 个可训练参数。请注意，基于全连接网络的神经网络架构通过与输入数据中的所有样本交互，利用了所有测量值。然而，这种处理方式并未针对测量值中的信息结构进行专门设计。另一方面，所提出的基于 DAFC 的神经网络利用信息结构来处理输入数据。因此，对于所考虑的 DOA 估计问题，这种方法的“归纳偏置” [51]并不合适，可能导致神经网络架构欠拟合。

2）性能评估指标：本小节讨论所提出的到达方向估计方法的性能评估准则。在本研究中，与 [38], 类似，通过集合间的豪斯多夫距离来评估一组信源的到达方向估计精度。集合 $\mathcal{A}$ 和 $\mathcal{B}$ 之间的豪斯多夫距离 d_H 定义如下：

$$d_H(\mathcal{A}, \mathcal{B}) = \max\left\{d(\mathcal{A}, \mathcal{B}), d(\mathcal{B}, \mathcal{A})\right\}, \tag{17}$$
$$d(\mathcal{A}, \mathcal{B}) = \sup\left\{\inf\left\{|\alpha - \beta| : \beta \in \mathcal{B}\right\} : \alpha \in \mathcal{A}\right\}.$$

注意，$d\ \mathcal{A}\ \mathcal{B} \neq d\ \mathcal{B}\ \mathcal{A}$ $\boldsymbol{\Theta} = \{\theta_m\}_{m=1}^M$ $\boldsymbol{\Theta} = \{\theta_m\}_{m=1}^M$ (,) (,)。令和ˆ ˆ ˆ分别表示真实到达方向和估计的到达方向集合。通过计算 Hausdorffˆ距离 $d_H(\boldsymbol{\Theta}, \boldsymbol{\Theta})$ 得到估计误差。对于任意一组包含 N 个样本（例如测试集）的示例，$\{\mathbf{X}^{(n)}, \mathbf{y}^{(n)}\}_{n=1}^N$，我们定义其均方根距离（RMSD），对应的真实值和估计值 DOAs, $\left\{\boldsymbol{\Theta}^{(n)}, \hat{\boldsymbol{\Theta}}^{(n)}\right\}_{n=1}^N$ as:

$$\text{RMSD} \triangleq \sqrt{\frac{1}{N}\sum_{n=1}^{N} d_H^2\left(\boldsymbol{\Theta}^{(n)}, \hat{\boldsymbol{\Theta}}^{(n)}\right)}. \tag{18}$$

角分辨率是衡量到达方向估计性能的关键指标之一。分辨概率通常用作角分辨率的性能评估指标。在所研究的问题中，两个信源之间以及信源与干扰之间的分辨情况用于性能评估。对于任意一个包含 M 个信源的示例，分辨事件 A_{res} 定义如下：

$$A_{res}\left(\boldsymbol{\Theta}, \hat{\boldsymbol{\Theta}}\right) \triangleq \begin{cases} 1, & \bigcap_{m=1}^{M} \xi_m \leq 2^\circ \text{ and } |\hat{\boldsymbol{\Theta}}| \geq M \\ 0, & \text{else} \end{cases}, \tag{19}$$
$$\xi_m \triangleq \min_{\hat{\theta} \in \hat{\boldsymbol{\Theta}}} |\theta_m - \hat{\theta}|,\ m = 1, \ldots, M.$$

例如，若一个场景中包含 M 个信源，则当每个真实到达方向都满足以下条件时，该场景被认为已成功分辨：a）存在一个足够接近的估计到达方向，ˆ ˆ $\theta \in \boldsymbol{\Theta}$，其间隔至多为 2°；b）至少存在 M 个到达方向估计。根据（18），分辨概率可定义为：

$$P_{res} = \frac{1}{N}\sum_{n=1}^{N} A_{res}\left(\boldsymbol{\Theta}^{(n)}, \hat{\boldsymbol{\Theta}}^{(n)}\right). \tag{20}$$

3）数据集：本小节介绍训练集和测试集的结构与构建方式。

(*a*) 训练集

所用训练集包含 $N_{train} = 10,000$ 个示例，并在每个训练轮次重新生成。对于每个示例，即一个输入-标签对 (X, y)，到达方向信源的数量 M 根据均匀分布和 $i.i.d.$ 分布 $\{1, \ldots, M_{max}\}$ 生成。训练集包含 10% 的无干扰示例和 90% 的含干扰示例。在含干扰示例中，90% 的示例按照以下方式生成：信源到达方向 $\{\theta_m\}_{m=1}^M$ 和干扰的到达方向 θ_c 在模拟视场内均匀分布。其余 10% 的示例按照以下方式生成： θ_c 在视场内均匀分布，而信源到达方向 $\{\theta_m\}_{m=1}^M$ 在区间 $[\theta_c - 8^\circ, \theta_c + 8^\circ]$ 内均匀分布。这种数据集构建方式使神经网络训练能够“聚焦”于信源与干扰到达方向间隔较近的复杂场景。通过将干扰角扩展参数 ρ 设为从均匀分布 U ($[0.7, 0.95]$) 中抽取，以及将干扰尖峰度参数 ν 设为从均匀分布 U ($[0.1, 1.5]$) 中抽取，使所提出的神经网络具备对干扰统计特性变化的泛化能力。每个含干扰示例的干扰噪声比，以及 {信干比$_m\}_{m=1}^M$ 或{信噪比 $_m\}_{m=1}^M$，均根据表 III 独立抽取。（b）测试集

测试集由 $N_{test} = 20,000$ 个样本组成。结果是对50次独立测试集实现的评估性能取平均后得到的。考虑到低快拍数工作区间，快拍数设为 $K = 16$，但IV-B2中的实验 (c) 除外。考虑到重尾干扰，尖峰度参数设为 $\nu = 0.2$。

干扰噪声比设为干扰噪声比 $= 5\ dB$，干扰角扩展参数设为 $\rho = 0.9$。所有信源的信号幅度均设为相同，$\sigma_1 = \cdots = \sigma_m$，但 IV-B2 中的实验 (b) 除外。

符号说明		数值
ρ	干扰角 扩展参数	$\sim$U $([0.7, 0.95])$
ν	干扰 尖峰度参数	$\sim$U $([0.1, 1.5])$
INR	INR	$\sim$U $([0, 10])$ $[dB]$
SIR_m	第 m 个信号源的信干比	$\sim$U $([-10, 10])$ $[dB]$
SNR_m	第 m 个信源的信噪比	$\sim$U $([-10, 10])$ $[dB]$

表 III：训练集参数。信噪比$_m$ 分布适用于无干扰样例。

B. 实验

1) 干扰中的单个信源：在此场景中，评估从干扰中分辨出单个信号源的能力。令 $M = 1$，其中 $\theta_1 = 0.55°$，且 $\theta_c = \theta_1 + \Delta\theta_c$ 满足 $\Delta\theta_c$ 表示单个信号源与干扰之间的角度间隔。偏移量用于模拟现实中的非网格条件。图3展示了所有评估方法的均方根偏差和分辨概率。

图3a 显示，基于全连接神经网络的方法无法在所有评估的角度间隔下将单个信源与干扰区分开来。这一结果印证了基于全连接神经网络的方法在到达方向估计中存在欠拟合局限；其原因在于，该架构直接处理输入数据，未进行任何结构化变换或基于模型的预处理。最小方差无失真响应和卷积神经网络在分辨能力方面表现相近，因为二者都只依赖二阶统计量，而在信源与干扰相距较远的场景中，这已足够。图 3a 显示，对于 $2° < \Delta\theta_c < 5°$ 最小方差无失真响应的性能有所下降，这是由于信源与干扰距离较近。当干扰与信源之间的角距离减小至低于 $5°$时，信源峰值与干扰峰值重合，因此分辨概率降低。角距离进一步减小时，合并后的峰值落入分辨窗口的概率会增加，从而使 P_{res}更高。图3a 显示，在角度间隔较小的场景中，所提出的基于 DAFC 的神经网络方法优于所有其他对比方法。这一观察结果证明，DAFC 能够利用输入数据中有助于分辨间隔较近的信源与干扰的信息。

图 3b 展示了所有所考虑的 DOA 估计方法的均方根偏差。所提出的基于DAFC的神经网络方法在低信干比下优于其他受测方法。在高信干比和较小角度间隔下，$\Delta\theta_c = 5°$，相对于强信源信号而言，干扰可以忽略不计，因此，基于 DAFC 的方法、卷积神经网络方法和最小方差无失真响应方法表现相近。对于较大的角度间隔，$\Delta\theta_c = 30°$，信号源与干扰充分分离，因此，到达方向估计误差主要由干扰到达方向 θ_c 引起。MVDR 谱在 $\theta_c = 30.55°$ 处包含一个峰值，因此，MVDR 的$RMSD = 30°$ 近似为常数。神经网络经过训练后会对干扰输出零概率。因此，基于神经网络的方法（全连接、卷积神经网络和 DAFC）能够实现更小的到达方向估计误差。基于 DAFC 的神经网络和卷积神经网络采用了更适合输入数据的结构化变换，因此，在均方根偏差方面优于基于全连接网络的神经网络方法。

2) 从干扰中分辨两个信源：本小节评估了在加性高斯白噪声和干扰环境下，所测试的到达方向估计方法在两个信源场景中的性能。

(a) 等强度信源的分辨

在以下实验中，评估了两个等功率信源之间的分辨能力，$M = 2$ $\theta_1 = -\frac{\Delta\theta}{2} + 0.55°$ $\theta_2 = \frac{\Delta\theta}{2} + 0.55°$，其中 和 ，。信源角度间隔上额外的非网格偏移代表了实际场景。在 $\Delta\theta$ 处的干扰对两个信源的影响相似。图展示了在以下场景中所测试方法的分辨概率：(a) 仅有加性高斯白噪声；(b) 存在空间有色干扰。

基于全连接神经网络的方法在所评估的两种场景中均无法分辨这两个目标。图4(a)显示，由于所提出的基于 DAFC 的神经网络方法对空间白噪声干扰具有泛化能力，因此在低信噪比和角度间隔较小的场景下，其性能优于最小方差无失真响应和卷积神经网络。图4(b)显示，当信干比为 $= -5\ dB$ 时，最小方差无失真响应和卷积神经网络的性能相比所提出的基于 DAFC 的神经网络方法显著下降。比较图4中的子图可见，当信干比为 $= -5\ dB$ 时，由于信源附近存在重尾空间有色干扰，最小方差无失真响应无法分辨角度间隔为 $\Delta\theta < 20°$ 的信源。然而，所提出的基于 DAFC 的神经网络方法能够抑制这种干扰并分辨信源，因此在信干比为 $= 0\ dB$ 和信干比为 $= -5\ dB$时均优于其他受测方法。

图 4 中的子图 (b) 显示了 CNN 和最小方差无失真响应在 $4° < \Delta\theta < 18°$ 和信干比 $= -5\ dB$下性能的非单调趋势，这在图 3a中也有所观察。对于 $4° < \Delta\theta < 8°$，信源更接近干扰波瓣的峰值，因此受到干扰的抑制较弱。随着 $\Delta\theta$ 在范围 $8° < \Delta\theta < 12°$内增大，信源到达方向逐渐接近干扰波瓣的“零陷”，这解释了分辨率的降低；而随着 $\Delta\theta$ 进一步增大， $16° < \Delta\theta$信源与干扰充分分离，因此分辨率提高。由此， 仅使用二阶统计量的最小方差无失真响应和基于卷积神经网络的方法无法分辨位于更强干扰附近的信源。

图5 展示了所有受测方法在 $\Delta\theta = 12°$ 和信干比 $= -5\ dB$ 条件下的平均空间谱。基于全连接神经网络的方法的平均空间谱未呈现两个明显的峰值，因此其分辨概率较低，见

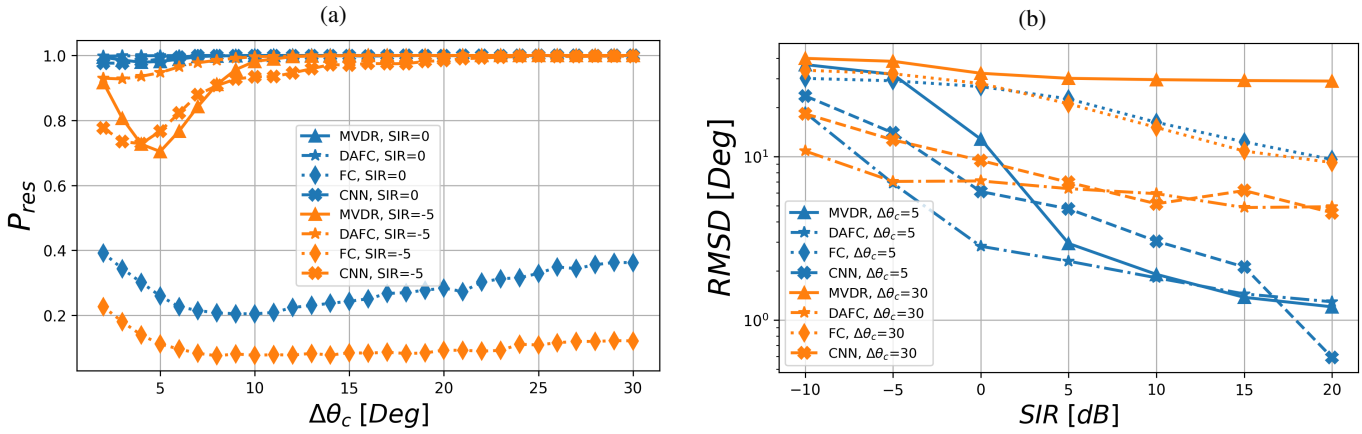


图3：单个信源位于 $\theta_1 = 0.55°$，干扰位于 $\theta_c = \theta_1 + \Delta\theta_c$ 的场景。(a) 分辨概率和 (b) 均方根偏差。

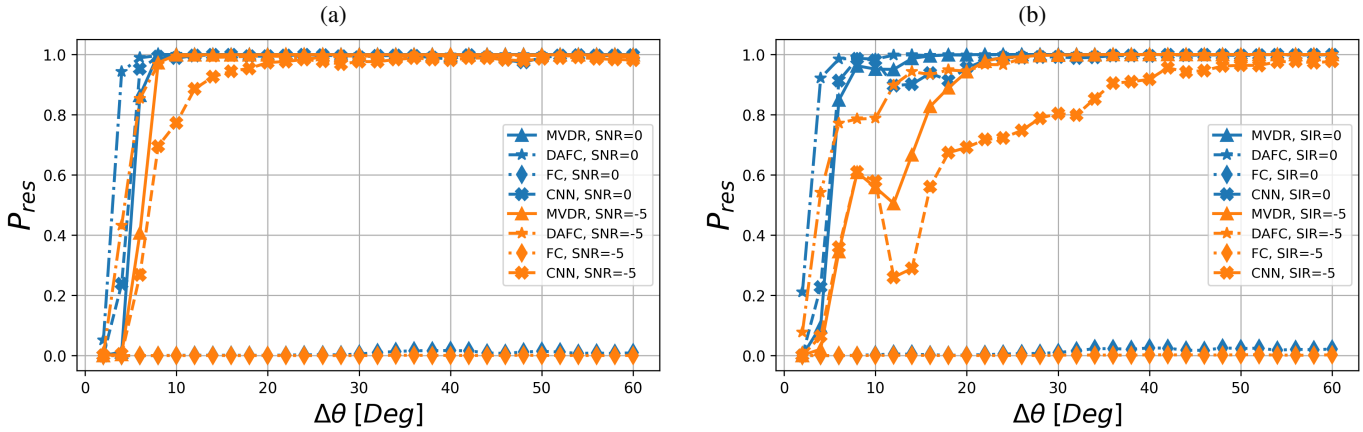


图4：两个信源分别位于 $\theta_{1、2} = \theta_c \pm \Delta\theta/2$，干扰位于 $\theta_c = 0.55°$ 时的分辨概率。(a) 仅含AWGN场景和 (b) 含干扰场景。

图4。MVDR 的“钟形”空间谱在 $\theta_{1,2}$ 处没有两个明显峰值，因为干扰“掩盖”了两个信源。CNN 和所提出的基于 DAFC 的神经网络方法的平均空间谱均呈现两个峰值。CNN 平均空间谱中的峰值较低，因此分辨概率较低。所提出的基于 DAFC 的神经网络方法的平均空间谱包含两个较高的峰值，因此在图 4中具有更高的分辨概率。

(b) 非等功率信源的分辨

图 6 展示了两个信源场景下的分辨概率，$M = 2$，在 $\theta_1 = -\Delta\theta/2 + 0.55°$，且$\theta_2 = +\Delta\theta/2 + 0.55°$ 干扰位于信源之间的情况下，干扰位于 $\theta_c = 0.55°$。第二个信源的信号强度设为 $\text{SIR}_1 = \text{SIR}_2 + 10\ dB$。将图 6 与图 4b进行比较可以看出，除 SIR $= 0\ dB$ 情况下 CNN 的分辨概率下降外，各竞争方法呈现出相似的趋势。另一方面，所提出的基于 DAFC 的 NN 方法在分辨概率方面优于其他测试方法。因此，图 6展示了所提出的基于 DAFC 的 NN 方法对于信源强度方差变化的泛化能力。CNN 和 MVDR 的 P_{res} 下降在 $10° < \Delta\theta < 20°$ 的原因与图 3a 和4b中出现的相同现象类似，该现象已在小节 IV-B2(a) 中解释。

(c) 快拍数对分辨的影响本实验研究快拍数 K 对于从重尾空间有色干扰中分辨两个邻近信源能力的影响。针对等强度信源的分辨场景，分别采用 K =4、8、16、32、64 个快拍，并针对每个 K 数值采用不同的神经网络训练实例重复实验。图7 展示了在 $\Delta\theta = 12°$ 和 $\theta_c = 0.55°$ 条件下，位于 $\theta_{1、2} = \theta_c \pm \Delta\theta/2$ 的两个等强度信源的分辨概率。

基于全连接网络的神经网络方法无法分辨这两个信源。对于信干比 $= 0\ dB$，随着 $= 0\ dB$增加，最小方差无失真响应、卷积神经网络和基于 DAFC 的神经网络方法的分辨概率单调递增

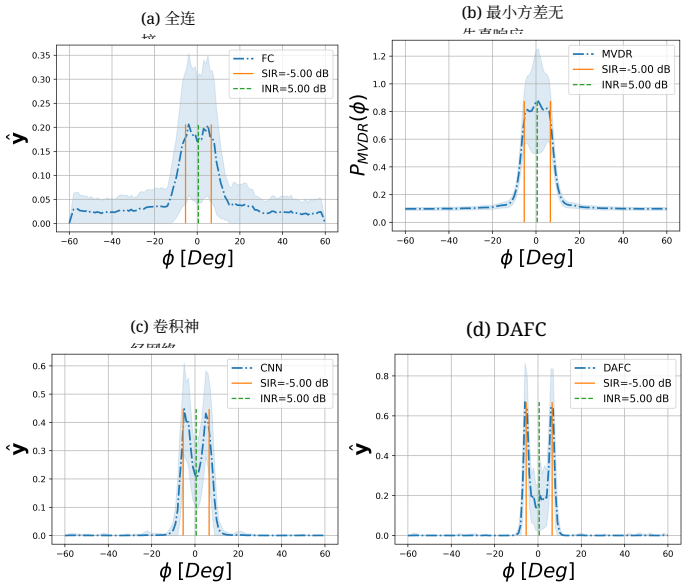


图5：信干比为 $= -5\ dB$、位置在 $\theta_{1,2} = \theta_c \pm \Delta\theta/2$ 的两个信源的空间谱，其中 $\Delta\theta = 12°$，且 $\theta_c = 0.55°$。蓝色虚线表示平均空间谱，颜色填充区域表示基于 2,000 个独立同分布样本得到的均值周围的标准差。橙色实线表示真实信源到达方向，绿色虚线表示干扰到达方向。

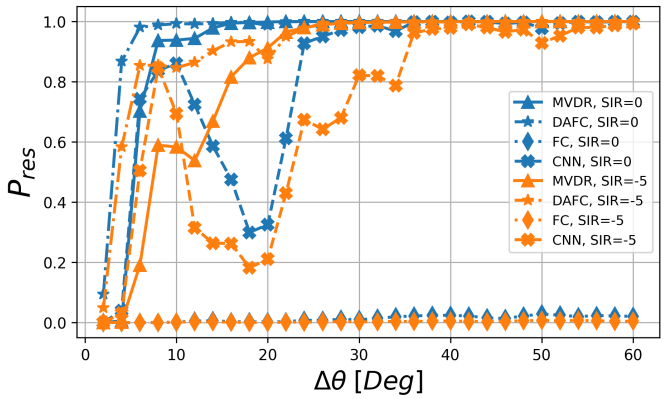


图6：两个信源位于$\theta_{1,2} = \theta_c \pm \Delta\theta/2$，干扰位于 $\theta_c = 0.55°$ 时的分辨概率。图例中的信干比表示第一个信源的信干比，SIR_1。第二个信源的信干比设为 $\mathrm{SIR}_2 = \mathrm{SIR}_1 + 10\ dB$。

。所提出的基于 DAFC 的神经网络方法略优于其他受测方法。当信干比较低，即信干比为 $= -5\ dB$ 时，所提出的基于 DAFC 的神经网络方法显著优于其他受测方法。这可以解释为，K 增加会提高输入数据矩阵$\mathbf{X}$中出现离群值的概率。因此，估计得到的自相关矩阵 $\hat{\mathbf{R}}_x$更容易受到干扰相关离群值的偏置，导致干扰“掩盖”信源。所提出的基于 DAFC 的神经网络方法不受这些因素的影响

离群值，并成功利用额外快拍中的信息提高分辨概率。

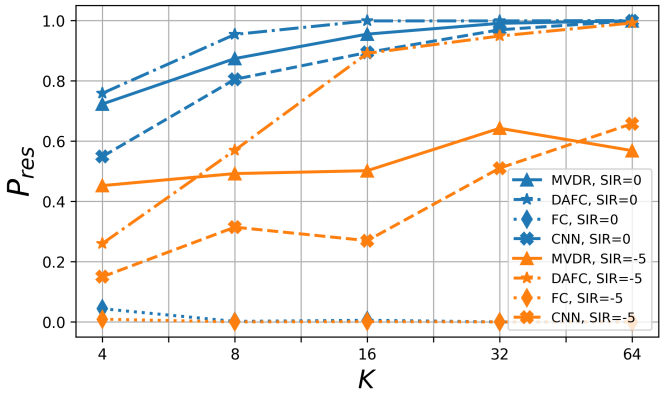


图7：两个信源位于$\theta_{1、2} = \theta_c \pm \Delta\theta/2$ 且 $\Delta\theta = 12°$时，干扰位于$\theta_c = 0.55°$时，分辨概率随快拍数 K的变化。

图 4、5、6和 7 展示了所提出的基于 DAFC 的神经网络方法如何通过执行域拟合变换，利用输入数据的信息结构，从而在邻近的重尾空间有色干扰、低信干比和小样本量情况下实现更强的分辨能力。

3）多信源定位：在多信源场景中，对所测试的到达方向估计方法的性能进行评估和比较。仿真了四个信源（$M = 4$），其角度间隔为 $\Delta\theta$：$\{\theta_1, \theta_2, \theta_3, \theta_4\} = \theta_c + \{-2\Delta\theta, -\Delta\theta, \Delta\theta, 2\Delta\theta\}$，其中 $\theta_c \sim \mathrm{U}(-15°, 15°)$ 代表信号源和干扰到达方向的一种现实情况。图8展示了各评估方法的均方根偏差。低信干比（SIR $< 0\ dB$）下，对于较大和较小的角度间隔，所提出的基于 DAFC 的神经网络方法均优于其他受测方法。在高信干比且角度间隔较小时，$\Delta\theta = 5°$，最小方差无失真响应方法的均方根偏差最低。原因在于这种情况下，相对于最小方差无失真响应谱中强信号源的主瓣，干扰可以忽略。然而，在角度间隔较大时，$\Delta\theta = 20°$，所提出的基于 DAFC 的神经网络方法显著优于其他受测方法。图9对此作出了解释，该图展示了各受测到达方向估计方法的谱。请注意，所提出的基于 DAFC 的神经网络方法抑制了干扰，而其他受测方法的谱在干扰到达方向 θ_c处含有高峰。这些峰会增大式（17）中的豪斯多夫距离，从而增大图8中其他受测方法的均方根偏差。

4) 多源枚举：本实验评估信号源数目估计性能。信号源的到达方向从以下数值集合中选取：$\{\theta_1, \theta_2, \theta_3, \theta_4\} = \theta_c + \{\Delta\theta, -\Delta\theta, -2\Delta\theta, 2\Delta\theta\}$ 使得对于M个信号源，到达方向选为前 M 个到达方向。干扰位于 $\theta_c \sim \mathrm{U}(-15°, 15°)$。将所提出的基于DAFC的神经网络方法与 MDL 和 AIC [19]进行比较。图 10 展示了 SIR 为 $= 0\ dB$时，MDL、AIC 和所提出的基于DAFC的神经网络的源枚举混淆矩阵。

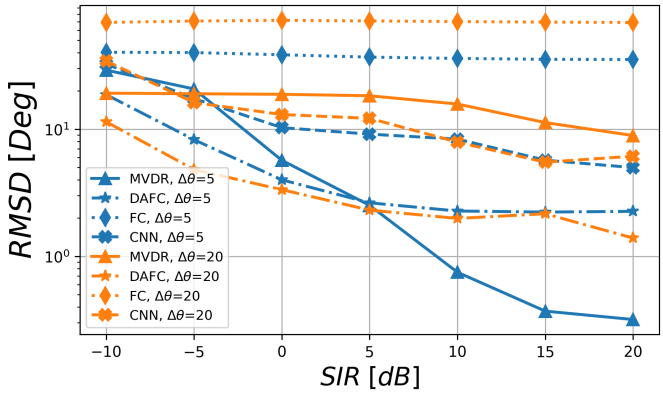


图 8： $M = 4$ 个信源位于 $\{\theta_1, \theta_2, \theta_3, \theta_4\} = \theta_c + \{-2\Delta\theta, -\Delta\theta, \Delta\theta, 2\Delta\theta\}$时的均方根偏差，其中 $\theta_c \sim \mathrm{U}(-15°, 15°)$。

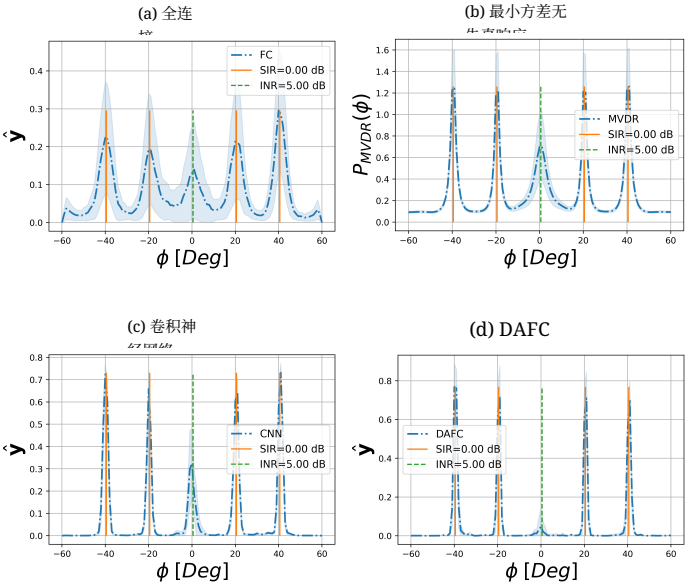


图 9：空间谱，四个信源的信干比为 $= 0\ dB$，位于 $\{\theta_1, \theta_2, \theta_3, \theta_4\} = \theta_c + \{-2\Delta\theta, -\Delta\theta, \Delta\theta, 2\Delta\theta\}$，其中 $\theta_c = 0.51°$ 和 $\Delta\theta = 20°$。蓝色虚线表示平均空间谱，颜色填充表示基于 2,000 个独立同分布样本得到的均值周围的标准差。橙色实线表示真实信源到达方向，绿色竖直虚线表示干扰到达方向。

图 10a 和 10b 表明，MDL 和 AIC 在空间有色干扰下，对每个真实 M 的信源数量预测都存在恒定偏差。图 10c展示了所提出的基于DAFC的神经网络方法在存在空间有色干扰时的信号源数目估计性能。基于DAFC的神经网络能够识别干扰，并通过对 θ_c附近的角度网格点输出较低概率，不将其计为信号源之一，从而获得更好的信源数目估计性能。

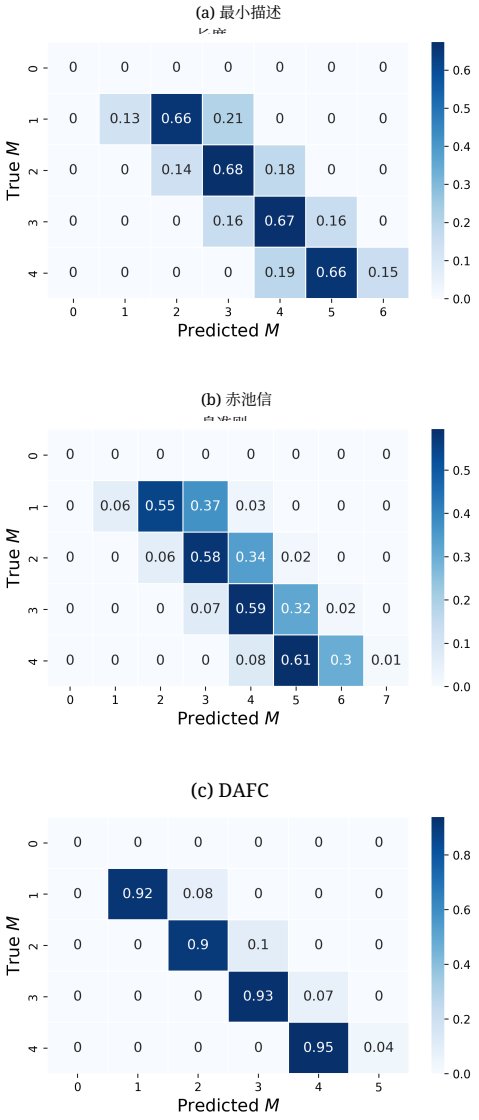


图 10：信源数估计的混淆矩阵，信干比 $=0\ \ dB$，信号源位于 $\{\theta_1, \theta_2, \theta_3, \theta_4\} = \theta_c + \{-2\Delta\theta, -\Delta\theta, \Delta\theta, 2\Delta\theta\}$，使用 $\theta_c \sim \mathrm{U}(-15°, 15°)$，以及$\Delta\theta = 15°$。（a）最小描述长度，（b）赤池信息准则，（c）所提出的基于 DAFC 的神经网络。

5）损失权重：本实验评估损失权重更新因子 $\{\beta^{(l)}\}_{l=1}^{N_w}$（见12）对 ~空间谱置信度的影响。令 $\mathbf{B}$ 表示所提出方法中使用的 $\{\beta^{(l)}\}_{l=1}^{N_w}$ 数值集合。损失权重 $\{w_i^{(t)}\}_{i=1}^{d}$由因子 $e_0^{(t)}$ 、 $e_1^{(t)}$ 根据（11）定义，用于权衡信号源/干扰所产生的惩罚与输出空间谱其余部分所产生的惩罚。

作为比较，我们设置 $\mathbf{B}_0 = \{10^{-6}, 3.98 \cdot 10^{-6}, 1.58 \cdot 10^{-5}$、$6.31 \cdot 10^{-5}$、$2.51 \cdot 10^{-4}$、$10^{-3}\}$，以及 $\mathbf{B}_1 = \{10^{-3}, 3.98 \cdot 10{-3}$、$0.0158$、$0.063$、$0.25$，$0.1\}$ 作为两组损失权重更新因子。对于 $\mathbf{B}_0$，，损失权重更新因子更接近 0。因此，损失权重更强调信号源/干扰，因为 $e_1^{(t)} \ll e_0^{(t)}$ 根据（11），这意味着

信号源/干扰网格点对应的 $w_i^{(t)}$ 更大。对于 $\mathbf{B}_1$ ，数值更接近 1。因此，损失权重在各网格点间分布得更均匀，因为 $e_1^{(t)} \approx e_0^{(t)}$ 。此处重复了 IV-B1 中的实验，采用基于 DAFC 的神经网络方法，并使用上述另外两个 $\mathbf{B}_0$,$\mathbf{B}_1$ 数值。

令 $\hat{}p_1$ 表示估计标签 $\hat{}\mathbf{y}$中分配给包含信号源的网格点的概率。令 $\hat{}p_0$ 表示 $\hat{}\mathbf{y}$中分配给非信号源网格点的概率最大值，但不包括信号源周围 5 个网格点的保护间隔。图 11展示了在不同的信号源与干扰角间隔下，$\hat{}p_1$ 和 $\hat{}p_0$ 的变化情况，其中信干比为 $= -5\ dB$。当$\mathbf{B}_0$, 时，信号源对损失值的贡献显著更高，因此分配给包含信号源的网格点的概率也更高。然而，由于非信号源网格点对损失值的贡献与包含信号源的网格点相比可以忽略不计，这会导致这些非信号源网格点获得更高的概率，从而使空间谱中的“虚警”峰增多，进而增加估计误差。相应地，当$\mathbf{B}_1$ 时，信号源对损失值的贡献较小，因此分配给包含信号源的网格点的概率较低，分配给非信号源网格点的概率也较低。

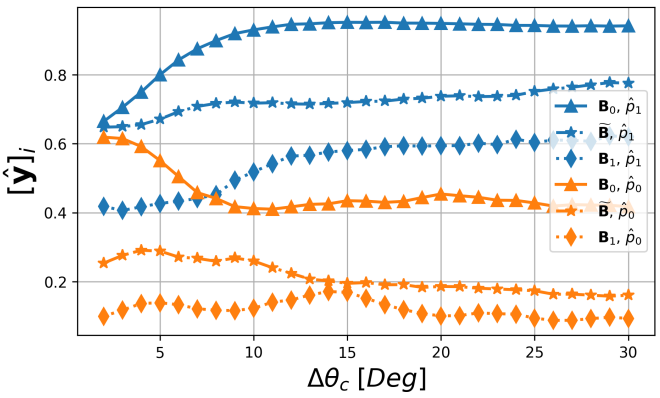


图 11：损失权重更新因子对基于 DAFC 的神经网络空间谱中概率水平的影响，单目标位于 $\theta_1 = 0.55°$，干扰位于 $\theta_c = \theta_1 + \Delta\theta_c$，信干比为 $= -5\ dB$。$\hat{}p_1$ 表示信号源所在网格点得到的概率。$\hat{}p_0$ 表示非信号源网格点得到的概率。

五、结论

本文研究了在重尾、非高斯且空间有色干扰下，对未知数量信源进行到达方向估计和信源数估计的问题。针对该问题，提出了一种基于 DAFC 的神经网络方法。DAFC 机制采用一种结构化变换，能够利用干扰的非高斯性对其进行抑制，同时保持较低的可学习参数复杂度。所提出的基于 DAFC 的神经网络方法通过损失权重调度程序进行优化，以获得干扰抑制空间谱，并利用统一神经网络完成到达方向估计和信源数估计。

将所提出方法的性能与最小方差无失真响应、基于卷积神经网络的方法和基于全连接网络的方法进行了比较。仿真结果表明，在分辨概率和以均方根偏差评估的估计精度方面，所提出的基于 DAFC 的神经网络方法具有优越性，尤其是在信号功率较弱、快拍数较少以及信源接近干扰的场景下。还将所提出的基于 DAFC 的神经网络方法的信源数目估计性能与最小描述长度和赤池信息准则进行了比较。结果表明，在所考虑的场景中，所提出方法的信源数目估计精度优于最小描述长度和赤池信息准则。

参考文献

[1] H. L. Van Trees, 《最优阵列处理：检测、估计与调制理论》第IV部分》。John Wiley & Sons, 2004年。[2] E. Ollila、D. E. Tyler、V. Koivunen 和 H. V. Poor, “复椭圆对称分布：综述、新成果与应用”, *IEEE*信号处理汇刊, 第60卷, 第11期, 第5597–5625页, 2012年。[3] J. Capon, “高分辨率频率-波数谱分析”, *IEEE*会刊, 第57卷, 第8期, 第1408–1418页, 1969年。[4] R. Roy 和 T. Kailath, “通过旋转不变技术估计信号参数的ESPRIT方法”, *IEEE*声学、语音与信号处理汇刊, 第37卷, 第7期, 第984–995页, 1989年。[5] R. Schmidt, “多发射源定位与信号参数估计”, *IEEE*《天线与传播汇刊》, 第34卷, 第3期, 第276–280页, 1986年。[6] A. Barabell, “提高基于特征结构的测向算法的分辨率性能”, 载于*ICASSP'83. IEEE*国际声学、语音与信号处理会议, 第8卷。IEEE, 1983年, 第336–339页。[7] O. Besson、Y. Abramovich 和 B. Johnson, “K分布噪声与高斯噪声混合情况下的到达方向估计”, 信号处理, 第128卷, 第512–520页, 2016年。[8] U. K. Singh、R. Mitra、V. Bhatia 和 A. K. Mishra, “基于核最小误差熵的非高斯杂波环境下MIMO雷达估计器”, *IEEE Access*, 第9卷, 第125 320–125 330页, 2021年。[9] E. Ollila 和 V. Koivunen, “基于散布矩阵的阵列处理器的影响函数与渐近效率：MVDR波束形成器案例”, *IEEE*信号处理汇刊, 第57卷, 第259期, 2008年, 第1、247页。[10] S. Fortunati、F. Gini、M. S. Greco、A. M. Zoubir 和 M. Rangaswamy, “复椭圆对称分布的半参数CRB与Slepian-Bangs公式”, *IEEE*信号处理汇刊, 第67卷, 第20期, 第5352–5364页, 2019年。[11] S. Luan、M. Zhao、Y. Gao、Z. Zhang 和 T. Qiu, “非高斯信号处理中的广义协方差及α稳定分布噪声下的GC-MUSIC”, 数字信号处理, 第110卷, 第102923页, 2021年。[12] K. Todros 和 A. O. Hero, “通过概率测度变换实现稳健的多重信号分类”, *IEEE*信号处理汇刊, 第63卷, 第5期, 第1156–1170页, 2015年。[13] N. Yazdi 和 K. Todros, “测度变换MVDR波束形成”, *IEEE*信号处理快报, 第27卷, 第1959–1963页, 2020年。[14] X. Zhang、M. N. El Korso 和 M. Pesavento, “SIRP噪声环境下的最大似然与最大后验到达方向估计”, 载于*2016*年*IEEE*国际声学、语音与信号处理会议（*ICASSP*）。IEEE, 2016年, 第3081–3085页。[15] ——, “SIRP杂波环境下的MIMO雷达目标定位与性能评估”, 信号处理, 第130卷, 第217–232页, 2017年。[16] B. Meriaux、X. Zhang、M. N. El Korso 和 M. Pesavento, “SIRP杂波环境下MIMO雷达的迭代边缘最大似然DOD和DOA估计”, 信号处理, 第155卷, 第384–390页, 2019年。[17] M. Trinh-Hoang、M. N. El Korso 和 M. Pesavento, “非高斯低秩干扰与噪声环境下的部分松弛稳健到达方向估计器”, 载于*ICASSP 2021-2021*年*IEEE*国际声学、语音与信号处理会议（*ICASSP*）。IEEE, 2021年, 第4365–4369页。[18] J. Dai 和 H. C. So, “用于抗离群值到达方向估计的稀疏贝叶斯学习方法”, *IEEE*信号处理汇刊, 第66卷, 第3期, 第744–756页, 2017年。

[19] M. Wax 和 T. Kailath，“基于信息论准则的信号检测”，IEEE声学、语音与信号处理汇刊，第33卷，第2期，第387–392页，1985年。[20] J. Fuchs、M. Gardill、M. L¨ubke、A. Dubey 和 F. Lurz，“从机器学习视角看汽车雷达到达方向估计”，IEEE Access，2022年。[21] J. Fuchs、R. Weigel 和 M. Gardill，“使用多层感知机对多个目标进行单快拍到达方向估计”，载于2019年IEEE MTT-S智能移动微波国际会议（ICMIM）。IEEE，2019年，第1–4页。[22] A. H. El Zooghby、C. G. Christodoulou 和 M. Georgiopoulos，“径向基函数网络在天线阵列到达方向估计中的性能”，IEEE《天线与传播汇刊》，第45卷，第11期，第1611–1617页，1997年。[23] B. Milovanovic、M. Agatonovic、Z. Stankovic、N. Doncov 和 M. Sarevska，“神经网络在空间信号处理中的应用”，载于第11届神经网络在电气工程中的应用研讨会。IEEE，2012年，第5–14页。[24] G. Ofek、J. Tabrikian 和 M. Aladjem，“用于估计两个信源到达方向的模块化神经网络”，《神经计算》，第74卷，第17期，第3092–3102页，2011年。[25] A. Barthelme 和 W. Utschick，“一种用于子阵采样天线阵列到达方向估计与模型阶数选择的机器学习方法”，IEEE信号处理汇刊，第69卷，第3075–3087页，2021年。[26] O. Bialer、N. Garnett 和 T. Tirer，“深度神经网络在到达角估计中的性能优势”，载于ICASSP 2019-2019年IEEE国际声学、语音与信号处理会议（ICASSP）。IEEE，2019年，第3907–3911页。[27] J. Cong、X. Wang、M. Huang 和 L. Wan，“基于深度神经网络的MIMO雷达稳健到达方向估计方法”，IEEE《传感器期刊》，第21卷，第6期，第7498–7507页，2020年。[28] M. Gardill、J. Fuchs、C. Frank 和 R. Weigel，“将多层感知机应用于汽车雷达传感器到达方向估计中的目标数量指示”，载于2018年IEEE第28届信号处理机器学习国际研讨会（MLSP）。IEEE，2018年，第1–6页。[29] J. Fuchs、R. Weigel 和 M. Gardill，“使用多层感知机估计汽车雷达传感器到达方向估计的模型阶数”，载于2019年IEEE无线传感器与传感器网络专题会议（WiSNet）。IEEE，2019年，第1–3页。[30] J. Rogers、J. E. Ball 和 A. C. Gurbuz，“通过深度学习估计信源数量”，载于2019年IEEE雷达会议（Radar-Conf）。IEEE，2019年，第1–5页。[31] ——，“使用深度学习稳健估计相干雷达信号源的数量”，IET《雷达、声呐与导航》，第15卷，第5期，第431–440页，2021年。[32] Z.-M. Liu、C. Zhang 和 S. Y. Philip，“基于深度神经网络的到达方向估计，并对阵列误差具有稳健性”，IEEE《天线与传播汇刊》，第66卷，第12期，第7315–7327页，2018年。[33] E. Ozanich、P. Gerstoft 和 H. Niu，“用于单快拍到达方向估计的深度网络”，载于2019年IEEE第29届信号处理机器学习国际研讨会（MLSP）。IEEE，2019年，第1–6页。[34] M. Gall、M. Gardill、T. Horn 和 J. Fuchs，“基于谱的单快拍超分辨率到达方向估计：深度学习方法”，载于2020年德国微波会议（GeMiC）。IEEE，2020年，第184–187页。[35] M. Gall、M. Gardill、J. Fuchs 和 T. Horn，“用于汽车雷达谱到达方向估计的神经网络表征学习”，载于2020年IEEE/MTT-S国际微波研讨会（IMS）。IEEE，2020年，第1031–1034页。[36] A. M. Ahmed、O. Eissa 和 A. Sezgin，“使用非理想天线阵列的深度自编码器进行相干信源到达方向估计”，载于2020年第三届移动太赫兹系统国际研讨会（IWMTS）。IEEE，2020年，第1–5页。[37] G. K. Papageorgiou 和 M. Sellathurai，“通过去噪自编码器在低信噪比区间进行到达方向估计”，载于2020年IEEE第21届无线通信信号处理进展国际研讨会（SPAWC）。IEEE，2020年，第1–5页。[38] G. K. Papageorgiou、M. Sellathurai 和 Y. C. Eldar，“用于低信噪比下到达方向估计的深度网络”，IEEE信号处理汇刊，第69卷，第3714–3729页，2021年。[39] E. Ozanich、P. Gerstoft 和 H. Niu，“用于到达方向估计的前馈神经网络”，《美国声学学会期刊》，第147卷，第3期，第2035–2048页，2020年。

[40] Y. Yao、H. Lei 和 W. He，《基于 A-CRNN 的未知信号源数量相干到达方向估计方法》，Sensors，第 20 卷，第 8 期，第 2296 页，2020年。[41] A. Barthelme 和 W. Utschick，《利用神经网络进行协方差矩阵重构的到达方向估计》，IEEE信号处理汇刊，第 28 卷，第 783–787 页，2021年。[42] A. M. Ahmed、A. A. Ahmad、S. Fortunati、A. Sezgin、M. S. Greco 和 F. Gini，《一种用于大规模 MIMO 雷达多目标检测的强化学习方法》，IEEE航空航天与电子系统汇刊，第 57 卷，第 5 期，第 2622–2636 页，2021 年。[43] D. Luo 、 Z. Ye 、 B. Si 和 J. Zhu，《高斯杂波中的深度 MIMO 雷达目标检测器》，IET《雷达、声呐与导航》，2022年。[44] W. Guo、T. Qiu、H. Tang 和 W. Zhang，《脉冲噪声环境下径向基函数神经网络在阵列处理中的性能》，数字信号处理，第 18 卷，第 2 期，第 168–178 页，2008。[45] D. Chen 和 Y. H. Joo，《利用卷积神经网络估计静止电磁信号三维波达方向的新方法》，Sensors，第 20 卷，第 10 期，第 2761 页，2020年。[46] ——，《利用卷积神经网络在脉冲噪声环境中进行多源波达方向估计》，《国际天线与传播期刊》，第 2022 卷，2022年。[47] S. Feintuch、H. Permuter、I. Bilik 和 J. Tabrikian，《相关重尾杂波中的基于神经网络的多目标检测》，已提交至 IEEE航空航天与电子系统汇刊，2022年。[48] P. Stoica 和 A. Nehorai，《条件与非条件波达方向估计的性能研究》，IEEE声学、语音与信号处理汇刊，第 38 卷，第 10 期，第 1783–1795 页，1990年。[49] M. Viberg、P. Stoica 和 B. Ottersten，《利用参数化信号在空间相关噪声场中的最大似然阵列处理》，IEEE信号处理汇刊，第 45 卷，1004，1997 4，第 996 页。[50] I. Goodfellow、Y. Bengio 和 A. Courville，《深度学习》。麻省理工学院出版社，2016年，http://www.deeplearningbook.org。[51] S. Shalev-Shwartz 和 S. Ben-David，《理解机器学习：从理论到算法》。剑桥大学出版社，2014年。[52] D. P. Kingma 和 J. Ba，《Adam：一种随机优化方法》，arXiv 预印本 arXiv:1412.6980，2014年。 [在线]。可访问：https://doi.org/ 10 48550 1412 6980 。/arXiv.。K. Harmanci、[53] J. Tabrikian 和 J. L. Krolik，《自适应最小方差波束形成与最优信号源定位之间的关系》，IEEE信号处理汇刊，第 48 卷，12，2000 1，第 1 页。



Stefan Feintuch 于2022年和2023年分别获得以色列贝尔谢巴内盖夫本-古里安大学电气与计算机工程理学学士和理学硕士学位。他的研究兴趣包括机器学习、深度学习、雷达和信号处理。



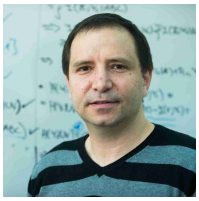
Joseph Tabrikian （IEEE会士）于1986年、1992年和1997年分别获得以色列特拉维夫特拉维夫大学电气工程理学学士、理学硕士和哲学博士学位。1996—1998年，他在北卡罗来纳州达勒姆的杜克大学电气与计算机工程系（ECE）担任助理研究教授。1998年，他加入以色列贝尔谢巴内盖夫本-古里安大学电气与计算机工程系，并于2017—2019年担任系主任。2019年5月，他创立了电气与计算机工程学院

并担任该委员会主席至2021年8月。他曾于2001—2004年和2011—2015年担任IEEE信号处理汇刊副编辑（AE），目前担任该刊高级领域编辑（SAE）。他曾分别于2012—2015年和2015—2018年担任IEEE信号处理快报副编辑和高级领域编辑。2010—2015年，他是IEEE传感器阵列与多通道（SAM）技术委员会成员，并担任IEEE SAM 2010研讨会的技术程序联合主席。2015—2021年，他担任EURASIP多传感器系统信号处理（SPMuS）委员会成员；2017—2022年，他是IEEE信号处理理论与方法技术委员会成员。他是IEEE会议和研讨会中7篇获奖论文的合著者。他的研究兴趣包括估计与检测理论、学习算法和雷达信号处理。



Igal Bilik （S’03-M’06-SM’21）分别于1997年、2003年和2006年获得以色列贝尔谢巴内盖夫本-古里安大学电气与计算机工程理学学士、理学硕士和哲学博士学位。2006—2008年，他在北卡罗来纳州达勒姆的杜克大学电气与计算机工程系担任博士后研究员。2008—2011年，他在达特茅斯马萨诸塞大学电气与计算机工程系担任助理教授。2011—

2019年，他在以色列通用汽车高级技术中心担任研究员，领导汽车雷达技术开发。2019—2020年，他领导通用汽车研发部门的智能感知与视觉组，负责开发最先进的汽车雷达、激光雷达和计算机视觉技术。自2020年10月起，Bilik博士担任内盖夫本-古里安大学电气与计算机工程学院助理教授。自2020年起，他担任IEEE航空航天与电子系统学会雷达系统专门委员会委员，并担任民用雷达委员会副主席。Bilik博士是IEEE以色列车辆技术分会的代理负责人。他拥有170多项专利发明，发表了60多篇同行评审学术论文，曾获IEEE RADAR 2005和IEEE RADAR 2006会议最佳学生论文奖、2006年IEEE第24届以色列电气与电子工程师大会学生论文奖，以及2017年通用汽车产品卓越奖。



Haim H. Permuter （M’08-SM’13）于1997年和2003年分别以最优等成绩获得以色列本-古里安大学电气与计算机工程理学学士和理学硕士学位，并于2008年在加利福尼亚州斯坦福大学获得电气工程哲学博士学位。1997年至2004年间，他在以色列国防军的一个研发部门担任军官。自2009年以来，他在本-古里安大学电气与计算机工程系任职，目前担任

教授，并担任电气工程Luck-Hille讲席。Haim还担任其所在系通信、网络安全和信息方向的负责人。Permuter教授曾获多项奖项，包括富布赖特奖学金、斯坦福研究生奖学金（SGF）、阿隆奖学金以及美以双边科学基金会伯格曼纪念奖。Haim于2013年至2016年担任IEEE信息论汇刊编委，并于2023年再次获任。