

基于可重构智能表面的二维高精度角度估计方法

郑乐^{1,2} 赵钊皓^{1,2} 卢珊珊³ 陈鹏⁴ 龙佳敏¹ 胡雪瑶^{*1,2}

(1. 北京理工大学雷达技术研究院, 北京 100081; 2. 北京理工大学重庆创新中心, 重庆 401135;
3. 西安电子工程研究所, 陕西西安 710100; 4. 东南大学毫米波全国重点实验室, 江苏南京 210096)

摘要: 可重构智能表面(Reconfigurable Intelligent Surface)因其提高频谱和能量使用效率、成本低等特点,被认为是未来无线通信和目标感知的关键性技术。RIS在平面上集成了大量低成本的无源反射元件,通过连接RIS的智能控制器,可以控制入射到这些可重构元件的信号的相位和幅度,从而重新配置入射信号的传播。波达方向(Direction of Arrival)估计问题是实现目标感知的重要组成部分,而RIS因其能够重新配置信号的特性被用来提高DOA估计的准确性。然而,在实际使用RIS时,由于元件之间的距离小于半波长而引起的互耦效应以及无法完美控制反射过程导致的反射失配(反射相位和幅度误差)等问题会严重影响RIS的性能。本文针对基于RIS系统的二维DOA估计问题,建立了考虑互耦效应和反射失配的RIS系统模型;并基于该模型,提出了一种新的二维角度估计方法用于DOA估计。该方法首先通过深度神经网络(Deep Neural Network)将RIS接收的信号进行重构,以降低互耦效应和反射失配的影响,再进一步使用非线性最小二乘法(Nonlinear Least Square)进行高精度的DOA估计。本文通过仿真验证了算法的估计性能,并与快速傅里叶变换(Fast Fourier Transformation)、正交匹配追踪(Orthogonal Matching Pursuit)等传统方法进行比较,结果表明相对于快速傅里叶变换、正交匹配追踪等传统方法新算法具有更好的估计性能。

关键词: DOA估计; 可重构智能表面; 非线性最小二乘; 互耦

中图分类号: TN959.1 **文献标识码:** A **DOI:** 10.16798/j.issn.1003-0530.2024.01.015

引用格式: 郑乐, 赵钊皓, 卢珊珊, 等. 基于可重构智能表面的二维高精度角度估计方法[J]. 信号处理, 2024, 40(1): 216-224. DOI: 10.16798/j.issn.1003-0530.2024.01.015.

Reference format: ZHENG Le, ZHAO Chuanhao, LU Shanshan, et al. A high-accuracy DOA estimation method using reconfigurable intelligent surface[J]. Journal of Signal Processing, 2024, 40(1): 216-224. DOI: 10.16798/j.issn.1003-0530.2024.01.015.

A High-Accuracy DOA Estimation Method Using Reconfigurable Intelligent Surface

ZHENG Le^{1,2} ZHAO Chuanhao^{1,2} LU Shanshan³ CHEN Peng⁴ LONG Jiamin¹ HU Xueyao^{*1,2}

(1. Radar Technology Research Institute, Beijing Institute of Technology, Beijing 100081, China;

2. Chongqing Innovation Center, Beijing Institute of Technology, Chongqing 401135, China;

3. Xi'an Electronic Engineering Research Institute, Xi'an, Shaanxi 710100, China;

4. The State Key Laboratory of Millimeter Waves, Southeast University, Nanjing, Jiangsu 210096, China)

收稿日期: 2023-09-25; 修回日期: 2023-11-29

*通信作者: 胡雪瑶 xueyao.hu@qq.com *Corresponding Author: HU Xueyao, xueyao.hu@qq.com

基金项目: 国家自然科学基金(62388102); 国家重点研发计划(2018YFE0202101, 2018YFE0202102, 2018YFE0202103)

Foundation Items: The National Natural Science Foundation of China (62388102); National Key R&D Program of China (2018YFE0202101, 2018YFE0202102, 2018YFE0202103)

Abstract: The reconfigurable intelligent surface (RIS) is considered a pivotal technology for future wireless communication and target perception due to its characteristics of enhancing spectrum and energy efficiency while being cost-effective. RIS integrates a multitude of low-cost passive reflecting elements on a planar surface, and by connecting them to an intelligent controller, it allows for the control of the phase and amplitude of signals incident on these reconfigurable elements, thereby reconfiguring the propagation of incident signals. Due to its ability to control the phase and magnitude of reflected signals, RIS can be utilized to enhance the performance of wireless communication and target sensing. The accurate estimation of the direction of arrival is a pivotal element in achieving target sensing objectives. RIS can substantially enhance the precision of DOA estimation through various strategies. One approach involves focusing radar beams in specific directions to amplify target signals while concurrently reducing interference. Additionally, RIS can be employed to adjust reflection paths, mitigating the adverse effects of multipath propagation. Traditional DOA estimation methods rely on phase difference information between antennas in scenarios with multiple receiving antennas. However, these methods have limitations. Conventional beamforming methods and similar beamforming techniques are associated with low resolution. Subspace-based methods like Multiple Signal Classification and maximum likelihood-based approaches like Maximum Likelihood parameter estimation methods, suffer from high computational complexity and susceptibility to environmental influences. With the continuous development of fields such as wireless communication and radar, researchers have gradually explored and combined deep learning to overcome the limitations of traditional DOA estimation methods. Nevertheless, practical implementation of RIS faces challenges such as mutual coupling effects arising from the proximity of elements being less than half a wavelength, as well as reflection mismatches (errors in reflection phase and amplitude) resulting from imperfect control of the reflection process, which significantly impact the performance of RIS. In this paper, we address the two-dimensional DOA estimation problem in RIS-based systems by establishing an RIS system model that takes into account mutual coupling effects and reflection mismatches. Based on this model, we propose a novel method for two-dimensional angle estimation in DOA estimation. This method initially reconstructs the signals received by RIS using a deep neural network to mitigate the effects of mutual coupling and reflection mismatches. Subsequently, it employs a nonlinear least squares technique for high-precision DOA estimation. Simulation results are presented to validate the algorithm's estimation performance, it has been demonstrated that the DNN reconstruction step effectively mitigates the impact of mutual coupling and reflection mismatches, leading to a significant enhancement in the algorithm's DOA estimation performance. Applying the Nonlinear Least Squares algorithm to estimate the reconstructed signals yields even more precise angle estimations. Therefore, in RIS systems affected by mutual coupling and reflection mismatches, the proposed method outperforms traditional approaches such as Orthogonal Matching Pursuit and Fast Fourier Transformation in terms of estimation performance.

Key words: DOA estimation; reconfigurable intelligent surface; nonlinear least square; mutual coupling

1 引言

可重构智能表面(RIS)是一项颇具吸引力的技术,可以提高频谱和能量的使用效率,具有低成本的特点,可以控制反射信号并提供可配置的无线传播环境^[1-2]。RIS通过控制二极管的开闭决定反射信号的相位,通过改变电阻的大小控制反射信号的幅度^[3]。因其可以控制反射信号相位和幅度的特点,RIS可用于提高无线通信和目标感知的性能。对于无线通信:已有研究提出了一种在近场传播条件下用于无线通信定位和定向的RIS系统^[4],以及可以实现发射分集和无源波束成形的RIS辅助通信系统^[5]。对于目标感知:随着覆盖范围的扩大,Aubry等学者开发了基于RIS的雷达系统,用以实现目标感知与定位^[6];同时,有文献证明通过调整RIS相

位,可以提高接收信号的信噪比,从而增强雷达系统的检测能力^[7]。

角度到达方向估计问题是实现目标感知的重要组成部分。传统的DOA估计方法为模型驱动类DOA估计方法,通过建立目标角度与回波之间的数学模型^[8-11],利用不同的数学方法进行求解,从而实现DOA估计。典型方法有常规波束形成法(Conventional Beam Forming)^[12]等波束形成类方法,多信号分类法(Multiple Signal Classification)^[13]等子空间类方法和最大似然参数估计方法(Maximum Likelihood)^[14]等最大似然类方法。但这些方法均存在着一定的不足之处,如:波束形成类方法的分辨率较低,子空间类方法和最大似然类方法存在计算复杂度高和受环境影响大等问题。且模型驱动类DOA估计方法只有在阵列模型无误差等理想条

件下,才可以实现高精度角度估计。实际应用时,天线通道幅相不一致、耦合效应等误差会引起实际回波模型和理论模型存在偏差,即存在阵列模型失配现象,导致模型驱动类 DOA 估计方法性能下降,甚至失效。随着无线通信和雷达等领域的不断发展,研究人员逐渐探索并结合深度学习来克服传统 DOA 估计方法的限制。这类方法也被称为数据驱动类 DOA 估计方法,基本思路是将角度估计问题转化为角度分类问题或回归问题,利用深度神经网络自适应学习从回波到波达方向之间的非线性映射关系,实现 DOA 估计。为了在非理想条件下实现高精度 DOA 估计,文献[15]提出了一种新颖的 DNN 来学习通道模型的统计数据并捕获角度域中的稀疏特征;文献[16]提出了一种基于径向基函数神经网络的 DOA 估计方法,并通过位置信息数据进行训练;文献[17]提出通过使用深度神经网络来学习信号与到达角度间的非线性关系从而进行 DOA 估计。

RIS 可以通过将雷达波束聚焦在特定方向以增强目标信号并减少干扰,或者调整反射路径来减小多径效应等多种方式,提高 DOA 估计的准确性。但采用 RIS 来估计目标方向时,存在互耦效应和反射失配等问题导致传统的模型驱动类 DOA 估计方法性能严重下降^[18]。为解决这一问题,一些学者提出了基于数据驱动的适用于 RIS 场景的估计和优化方法。文献[19]给出了一种基于 RIS 系统地使用深度展开网络的 DOA 估计方法;文献[20]利用全连接网络构建自动编码器实现回波去噪和阵列误差校准,接着利用深度神经网络实现角度估计;然而上述两种方法需要大量的网络训练时间和测试时间,且网络参数量较多。文献[21]提出了一种基于无人机群的低成本测向系统,通过接收的 RIS 反射信号来进行 DOA 估计;该方法在非均匀线性 RIS 阵列中能够准确地估计 DOA,然而在二维 DOA 问题中难以实现高精度估计。

针对上述问题,本文结合深度神经网络(DNN)和非线性最小二乘方法(NLS)提出了一种新的适用于 RIS 系统的 DOA 估计方法。该方法在提高 DOA 估计性能方面的优点是 DNN 可以高精度地重构接收信号,降低互耦效应和反射失配的影响,而 NLS 可以准确估计二维 DOA。因此,在具有二维 RIS 和一个全功能通道的低成本系统中,该方法具有优异的 DOA 估计性能。本文章节安排如下:第2节将介绍基于 RIS 的 DOA 估计系统模型;第3节对

所提角度估计方法进行系统介绍,并在第4节介绍仿真实验及结果;最后对全文做出总结。

2 基于 RIS 的 DOA 估计系统模型

2.1 RIS 的互耦与反射失配模型

图1为 M 行 N 列的二维 1-bit RIS 系统模型,第 m 行 ($m=0, 1, \dots, M-1$) n 列 ($n=0, 1, \dots, N-1$) 元件的位置为 (md_r, nd_c) , 其中 d_c 是相邻 RIS 元件之间的水平距离, d_r 是相应的垂直距离。RIS 阵面可以接收来自多个目标的信号,并反射到传感器上,传感器仅使用一个全功能通道来接收信号并进行角度估计。

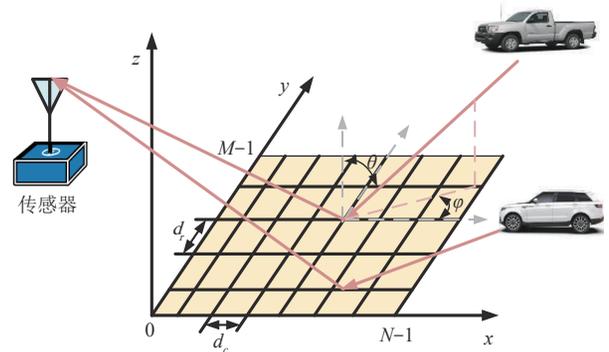


图1 基于RIS的传感模型

Fig. 1 The RIS-based sensing model

不同于传统天线阵列, RIS 相邻元件之间的距离可以小于半波长,各个元件之间存在互耦效应,导致其信号存在相关性。且实际的 RIS 不是完全对称的,元件之间的互耦并不相同,特别是对于边缘 RIS 元件。因此,我们引入互耦矩阵 $\mathbf{C} \in \mathbf{C}^{MN \times MN}$ 来描述 RIS 元件之间的互耦效应,互耦矩阵 \mathbf{C} 的第 $mN+n$ 行 $m'N+n'$ 列的元素 $C_{mN+n, m'N+n'}$ 为 RIS 第 m 行 n 列元件与第 m' 行 n' 列元件之间的耦合系数。

出于实际考虑, RIS 无法完美控制反射过程,会产生反射失配问题。当不存在反射失配时, RIS 的反射系数可以写为:

$$g_{m,n}(t) = \begin{cases} 1, & b_{m,n}(t) = 0 \\ -1, & b_{m,n}(t) = 1 \end{cases} \quad (1)$$

其中 $b_{m,n}(t)$ 为 RIS 第 m 行 n 列元件在时间 t 时的 FPGA 控制信号。当 $b_{m,n}(t) = 1$ 时, RIS 对接收信号的幅度和相位进行控制,否则不改变接收信号。当存在反射失配时,我们以 $b_{m,n}(t) = 0$ 处的反射系数为参考,反射系数可以写为:

$$g_{m,n}(t) = \begin{cases} 1, & b_{m,n}(t) = 0 \\ -B_{m,n} e^{j\beta_{m,n}}, & b_{m,n}(t) = 1 \end{cases} \quad (2)$$

其中我们使用 $B_{m,n} \in [0, 1]$ 和 $\beta_{m,n} \in [0, 2\pi)$ 来描述 FPGA 控制信号为 1 时的反射失配。

2.2 RIS 的角度估计模型

本文尝试在目标信号未知、存在互耦效应和反射失配的情况下, 使用 RIS 和传感器根据接收信号估计 K 个目标的方位角和俯仰角, 第 k 个 ($k = 0, 1, \dots, K-1$) 目标的方位角和俯仰角为 $\varphi_k \in [-90^\circ, 90^\circ]$ 和 $\theta_k \in [0^\circ, 180^\circ]$ 。如图 1 所示, 以零点位置的 RIS 元件为参考, 第 (m, n) 个元件接收到的信号可表示为:

$$r_{m,n}(t) = \sum_{k=0}^{K-1} e^{j\psi_{m,n}(\varphi_k, \theta_k)} s_k(t) \quad (3)$$

其中 $s_k(t)$ 为第 k 个目标信号, $\psi_{m,n}$ 表示 m 行 n 列元件导致的相位变化, 其数学形式为:

$$\psi_{m,n}(\varphi_k, \theta_k) \triangleq \frac{-2\pi}{\lambda} (nd_c \sin \theta_k \sin \varphi_k + md_r \cos \theta_k) \quad (4)$$

这里, λ 表示波长。

为了更好的估计二维角度, RIS 采用 FPGA 来控制反射信号的幅度和相位, 第 (m, n) 个元件处的反射信号可以写为:

$$z_{m,n}(t) = B_{m,n}(t) e^{j\beta_{m,n}(t)} r_{m,n}(t) \quad (5)$$

其中反射系数 $B_{m,n}(t) e^{j\beta_{m,n}(t)}$ 表示 RIS 元件对信号的反射程度, $B_{m,n}(t) \in [0, 1]$ 表示反射幅度, $\beta_{m,n}(t) \in [0, 2\pi)$ 表示反射相位。由于反射信号的功率小于入射信号的功率, 因此假设 $B_{m,n} \leq 1$ 。将只用一个全功能通道的传感器放置在 RIS 的前面, 方位角为 0° , 俯仰角为 90° 。传感器接收的反射信号可表示为:

$$y(t) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} z_{m,n}(t) + \omega(t) \quad (6)$$

其中 $\omega(t)$ 是加性高斯白噪声。

为简化问题, 假设接收信号为窄带信号, 对 $y(t)$ 进行等间隔采样后, 可以表示为向量形式:

$$y \triangleq [y(0), y(T), \dots, y((P-1)T)]^T \in \mathbf{C}^{P \times 1} \quad (7)$$

这里, T 为采样间隔, P 为样本数。定义 RIS 的系统模型为:

$$y = \mathbf{GAS} + \omega \quad (8)$$

其中 A 为导向矢量矩阵, G 为反射矩阵, ω 和 S 分别为噪声和目标信号。定义导向矢量矩阵 A 为:

$$A \triangleq [\alpha(\theta_0, \varphi_0), \alpha(\theta_1, \varphi_1), \dots, \alpha(\theta_{K-1}, \varphi_{K-1})] \in \mathbf{C}^{MN \times K} \quad (9)$$

其中导向矢量 $\alpha(\theta, \varphi) \triangleq [e^{j\psi_{0,0}(\theta, \varphi)}, \dots, e^{j\psi_{M-1,N-1}(\theta, \varphi)}]^T \in \mathbf{C}^{MN \times 1}$ 。

定义反射矩阵 G 为:

$$G \triangleq [g(0), g(T), \dots, g((P-1)T)]^T \in \mathbf{C}^{P \times MN} \quad (10)$$

反射矩阵 G 的第 p 列为 $g(pT) \triangleq [g_{0,0}(pT), \dots, g_{M-1,N-1}(pT)]^T \in \mathbf{C}^{MN \times 1}$ 。 ω 和 S 的信号形式分别为:

$$\omega \triangleq [\omega(0), \omega(T), \dots, \omega((P-1)T)]^T \in \mathbf{C}^{P \times 1} \quad (11)$$

$$S \triangleq [s_0, s_1, \dots, s_{K-1}]^T \in \mathbf{C}^{K \times 1} \quad (12)$$

式(8)表示的系统模型仅适用于理想场景, 综合考虑实际 1-bit RIS 中的互耦效应和反射失配的影响, 传感器的接收信号可以重写为:

$$\tilde{y} = (\mathbf{B} \odot \mathbf{G}) \mathbf{C} \mathbf{A} \mathbf{S} + \omega \quad (13)$$

其中 \odot 为 Hadamard 乘积, 反射矩阵 G 的元素为 ± 1 , 矩阵 B 描述反射失配。当同一位置 G 的元素为 1 时, B 的元素为 1; 当 G 为 -1 时, B 为 $-B_{m,n} e^{j\beta_{m,n}}$ 。矩阵 C 描述了 RIS 元件之间的互耦效应。

3 基于 RIS 的 DOA 估计方法

为了在基于 RIS 的系统中, 精确估计目标的二维 DOA, 关键的一步是减少因 RIS 元件之间的互耦效应以及无法完美控制反射过程所产生的反射失配等问题的影响。为解决上述问题, 本文结合 DNN 和 NLS 提出了一种新的 DOA 估计算法, 以在 RIS 系统中提高二维 DOA 估计的准确性。所提方法具体步骤如图 2 所示, 先将 RIS 接收的信号通过 DNN 进行重构, 降低互耦效应和反射失配的影响, 再进一步使用 NLS 算法进行高精度的 DOA 估计。

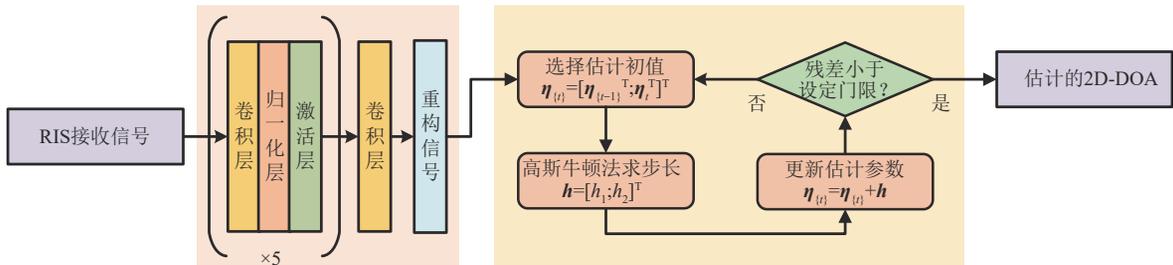


图2 所提方法估计 DOA 的步骤

Fig. 2 The steps for the proposed method to estimate the DOA

3.1 基于DNN的信号重构

当采用基于RIS的系统进行目标方向估计时,互耦效应和反射失配会显著降低传统的模型驱动类DOA估计方法估计性能。为了克服互耦效应和反射失配对传统模型驱动类DOA估计方法的影响,我们引入了数据驱动类DOA估计方法,DNN能够自适应地学习输入数据的各种信息,并拥有优秀的非线性拟合能力,理论上能够拟合任何形式的函数。当阵列存在误差时,DNN可以通过自适应更新参数权重,利用非线性性质拟合出理想回波模型。这一步我们采用卷积网络来实现,将输入信号经过一系列卷积层进行特征提取和压缩。再将提取和压缩后的特征重新映射为与输入信号相同尺寸的信号。这个过程中,卷积层会对信号进行非线性变换和重构,从而降低了互耦效应和反射失配的影响。为了使用卷积网络,将信号重写为 $\tilde{\mathbf{y}}_{\text{RI}} \triangleq [\mathbf{R}\{\tilde{\mathbf{y}}\}^T, \mathbf{I}\{\tilde{\mathbf{y}}\}^T]^T \in \mathbf{R}^{2P \times 1}$ 用作DNN输入。DNN输出的重构信号表示为 $\mathbf{z}_{\text{RI}} \triangleq [\mathbf{R}\{\mathbf{z}\}^T, \mathbf{I}\{\mathbf{z}\}^T]^T \in \mathbf{R}^{2P \times 1}$,与输入信号具有相同的大小。在激活层中,采用ReLU(Rectified Linear Unit)函数进行非线性激活,定义为:

$$f_{\text{ReLU}}(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (14)$$

为了训练DNN,使用以下损失函数:

$$f_{\text{Loss}}(\mathbf{z}_{\text{RI}}) = \frac{1}{2P} \|\mathbf{z}_{\text{RI}} - \mathbf{y}_{\text{RI}}\|_2^2 \quad (15)$$

其中定义 $\mathbf{y}_{\text{RI}} \triangleq [\mathbf{R}\{\mathbf{y}\}^T, \mathbf{I}\{\mathbf{y}\}^T]^T$ 为没有互耦效应和反射失配影响的完美系统模型的接收信号。通过网络训练后,输出的重构信号可以逼近完美系统模型

3.2 基于NLS的测角

3.2.1 角度估计模型

接收信号经过DNN重构后,进一步应用非线性最小二乘法方法进行角度估计。信号模型可重写为:

$$\mathbf{z}_{\text{RI}} = \mathbf{A}(\theta, \varphi) \mathbf{S} + \boldsymbol{\omega} \quad (16)$$

通过求解下面的优化问题,以获取角度的最优估计:

$$\{\hat{\theta}, \hat{\varphi}\} = \arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \|\mathbf{z}_{\text{RI}} - \mathbf{A}(\theta, \varphi) \mathbf{S}\|_2^2 \quad (17)$$

定义函数 $\mathbf{f}(\theta, \varphi) = \mathbf{z}_{\text{RI}} - \mathbf{A}(\theta, \varphi) \mathbf{S}$, DOA估计模型的代价函数为 $\mathbf{F}(\theta, \varphi) = \mathbf{f}^H(\theta, \varphi) \mathbf{f}(\theta, \varphi)$, $\boldsymbol{\eta} = [\theta; \varphi]$, 则式(17)可以写为:

$$\{\hat{\boldsymbol{\eta}}\} = \arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \|\mathbf{z}_{\text{RI}} - \mathbf{A}(\theta, \varphi) \mathbf{S}\|_2^2 =$$

$$\arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \mathbf{f}^H(\theta, \varphi) \mathbf{f}(\theta, \varphi) = \arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \mathbf{F}(\theta, \varphi) \quad (18)$$

函数 $\mathbf{f}(\theta, \varphi)$ 为变量 θ, φ 的非线性函数,通过非线性最小二乘法可得到参数 θ, φ 的估计值。当 θ, φ 给定时,可以得到 \mathbf{S} 的最优估计为:

$$\hat{\mathbf{S}} = \mathbf{A}^\dagger(\theta, \varphi) \mathbf{z}_{\text{RI}} \quad (19)$$

其中 $\mathbf{A}^\dagger(\theta, \varphi)$ 是 $\mathbf{A}(\theta, \varphi)$ 的伪逆矩阵,表示为 $\mathbf{A}^\dagger(\theta, \varphi) = [\mathbf{A}^H(\theta, \varphi) \mathbf{A}(\theta, \varphi)]^{-1} \mathbf{A}^H(\theta, \varphi)$ 。将 $\hat{\mathbf{S}}$ 和 $\mathbf{A}^\dagger(\theta, \varphi)$ 代入式(17)得:

$$\hat{\boldsymbol{\eta}} = \arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \|\mathbf{z}_{\text{RI}} - \mathbf{A}(\theta, \varphi) \mathbf{A}^\dagger(\theta, \varphi) \mathbf{z}_{\text{RI}}\|_2^2 = \arg \min_{\theta, \varphi \in \mathbf{R}^{K \times 1}} \|(\mathbf{I} - \mathbf{A}(\theta, \varphi) \mathbf{A}^\dagger(\theta, \varphi)) \mathbf{z}_{\text{RI}}\|_2^2 \quad (20)$$

非线性方程无法直接求出解析解,因此采用迭代的方法逐步接近最优解。寻找迭代步长 $\mathbf{h} = [h_1; h_2]^T$,使得 $\mathbf{F}(\hat{\boldsymbol{\eta}} + \mathbf{h}_1, \hat{\boldsymbol{\eta}} + \mathbf{h}_2) < \mathbf{F}(\hat{\boldsymbol{\eta}}, \hat{\boldsymbol{\eta}})$ 成立。进行迭代优化需要估计初值,在迭代优化前选择与残余相关系数最大的原子添加到支持集中,作为优化算法的初值。角度范围离散为 $J \times J$ 个网格 $\tilde{\boldsymbol{\eta}}$,构建字典 \mathbf{D} ,选择与残余 $\mathbf{r}_{[t-1]}$ 相关系数最大的原子作为第 t 个目标的初始值,并添加到支持集中,即:

$$\mathbf{D} = [\mathbf{a}(\theta_1, \varphi_1), \dots, \mathbf{a}(\theta_1, \varphi_J), \mathbf{a}(\theta_2, \varphi_1), \dots, \mathbf{a}(\theta_2, \varphi_J), \dots, \mathbf{a}(\theta_J, \varphi_1), \dots, \mathbf{a}(\theta_J, \varphi_J)] \quad (21)$$

$$\boldsymbol{\eta}_t = \arg \max_{\boldsymbol{\eta} \in \tilde{\boldsymbol{\eta}}} \left\{ \left| \mathbf{D}^H \mathbf{r}_{[t-1]} \right| \right\} \quad (22)$$

$$\boldsymbol{\eta}_{[t]} = [\boldsymbol{\eta}_{[t-1]}^T; \boldsymbol{\eta}_t^T]^T \quad (23)$$

不断迭代选择合适的步长 \mathbf{h} 更新 $\boldsymbol{\eta}_{[t]}$ 逐步获得更优的估计结果,并通过设置残余门限来控制迭代次数,残余 $\mathbf{r}_{[t]}$ 基于如式(24)所示的最小二乘法更新。

$$\mathbf{r}_{[t]} = \mathbf{z}_{\text{RI}} - \mathbf{A}(\boldsymbol{\eta}_{[t]}) \mathbf{A}^\dagger(\boldsymbol{\eta}_{[t]}) \mathbf{z}_{\text{RI}} \quad (24)$$

3.2.2 迭代优化算法

非线性最小二乘法常见的迭代优化算法有梯度下降法,高斯-牛顿法^[22],莱文贝格-马夸特法^[23]。本文采用高斯-牛顿法进行迭代优化。对函数 $\mathbf{f}(\theta, \varphi)$ 进行泰勒展开,即:

$$\mathbf{f}(\theta + h_1, \varphi + h_2) = \mathbf{f}(\theta, \varphi) + \mathbf{J}(\theta, \varphi) \mathbf{h} + \mathbf{o}(\|\mathbf{h}\|^2) \quad (25)$$

其中 $\mathbf{J}(\theta, \varphi)$ 是函数 $\mathbf{f}(\theta, \varphi)$ 的雅可比矩阵, $\mathbf{h} = [h_1; h_2]^T$ 是扰动项。当 \mathbf{h} 足够小时, $\mathbf{o}(\|\mathbf{h}\|^2)$ 可以忽略。对 \mathbf{h} 的估计可以通过下面的最小二乘获得:

$$\mathbf{h} = \arg \min_{\mathbf{h} \in \mathbf{R}^{K \times 1}} \mathbf{F}(\theta, \varphi) \approx \arg \min_{\mathbf{h} \in \mathbf{R}^{K \times 1}} \|\mathbf{f}(\theta, \varphi) + \mathbf{J}(\theta, \varphi) \mathbf{h}\|_2^2 \quad (26)$$

为了简化表达,下文以 f 表示 $f(\theta, \varphi)$, J 表示 $J(\theta, \varphi)$, $L(\mathbf{h})$ 表示 $\|f(\theta, \varphi) + J(\theta, \varphi)\mathbf{h}\|_2^2$, 则:

$$L(\mathbf{h}) = \mathbf{f}^H \mathbf{f} + 2\text{Re}\{\mathbf{h}^H \mathbf{J}^H \mathbf{f}\} + \mathbf{h}^H \mathbf{J}^H \mathbf{J} \mathbf{h} \quad (27)$$

对 $L(\mathbf{h})$ 分别进行一阶、二阶求导可得:

$$L'(\mathbf{h}) = 2\text{Re}\{\mathbf{J}^H \mathbf{f}\} + 2\text{Re}\{\mathbf{J}^H \mathbf{J}\} \mathbf{h} \quad (28)$$

$$L''(\mathbf{h}) = 2\text{Re}\{\mathbf{J}^H \mathbf{J}\} \quad (29)$$

$L''(\mathbf{h})$ 是对称的,当矩阵 J 满秩时,矩阵 $L''(\mathbf{h})$ 为正定矩阵。此时,求函数的最小值可转换为求解 $L'(\mathbf{h}) = 0$ 的线性问题,即:

$$2\text{Re}\{\mathbf{J}^H \mathbf{J}\} \mathbf{h} = -2\text{Re}\{\mathbf{J}^H \mathbf{f}\} \quad (30)$$

易求 $F(\theta, \varphi)$ 的梯度矩阵 \mathbf{g} 和二阶导矩阵 \mathbf{H} 分别为 $\mathbf{g} = 2\text{Re}\{\mathbf{J}^H \mathbf{f}\}$, $\mathbf{H} = 2\text{Re}\{\mathbf{J}^H \mathbf{J}\}$, 则步长 \mathbf{h} 可通过 $\mathbf{h} = -\mathbf{H}^{-1} \mathbf{g}$ 解得。

4 仿真结果

本节验证了所提方法在不同场景下的性能,仿真参数如表 1 所示。描述互耦效应和反射失配的参数根据实际 RIS 设置,互耦矩阵 C 各元素的幅度在区间 $[0.1, 0.4]$ 上服从均匀分布,相位在区间 $[0, 2\pi)$ 上服从均匀分布;反射失配矩阵 B 各元素的幅度在区间 $[0.5, 1.5]$ 上服从均匀分布,相位在区间 $[-\pi/6, \pi/6)$ 上服从均匀分布。设置样本数 P 为 128,该参数对于 DOA 估计也很重要,可根据 RIS 大小和目标数量来选择。

用于信号重构的 DNN 结构如图 3 所示,结构参数如表 2 所示。RIS 接收信号经过 6 个卷积层进行特征提取和压缩,并使用 ReLu 函数进行激活后,得到与输入信号大小相同的重构信号。在训练期间使用反向传播更新网络权重。训练 DNN 和重构接收信号的损失函数值如图 4 所示,训练数据集通过在 SNR 从 20 dB 到 50 dB 的场景中改变接收信号并随机选择互耦效应和反射失配的值来生成。如图 4

表 1 仿真参数

参数	数值
相邻 RIS 元件之间的距离	$d_r = d_c = 0.4\lambda$
RIS 行数	$M = 16$
RIS 列数	$N = 16$
样本数	$P = 128$
目标数	$K = 2$
目标方位角	$[-30^\circ, 30^\circ]$
目标俯仰角	$[20^\circ, 80^\circ]$

表 2 网络结构参数

参数	取值
网络层数	6
网络输出层激活函数	ReLu 函数
优化器及其参数	Adam; 学习率: 10^{-4}
批处理数	64
卷积核大小	3
卷积核步长	1
填充方式	1
训练轮数	10^4

所示,当训练数大于 100 时,损失函数趋近于 0,输出的重构信号可以逼近完美系统模型的信号。

在训练 DNN 后,对重构的信号使用 NLS 算法进行角度估计,并展示在不同 SNR 场景下的二维 DOA 估计性能。并将所提出的方法与正交匹配追踪(OMP)^[24]、快速傅里叶变换(FFT)、DNN-OMP、DNN-FFT 和 DNN-DANM^[18]方法进行比较。DNN-OMP 和 DNN-FFT 方法与所提方法相似,先使用 DNN 重构接收信号,再使用 OMP 和 FFT 算法估计目标 DOA。角度估计性能通过均方根误差来衡量,

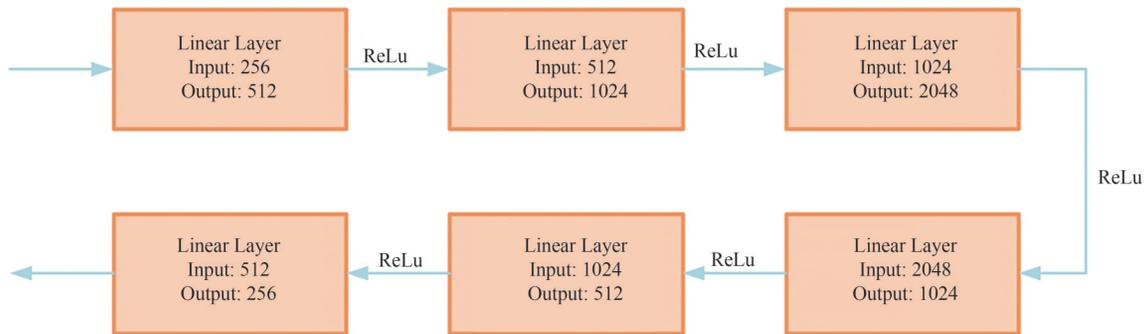


图 3 用于信号重构的 DNN 结构

Fig. 3 The DNN structure for the signal reconstruction

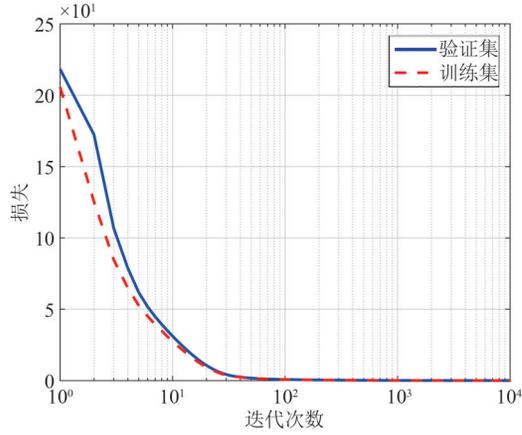


图4 训练损失函数值

Fig. 4 The values of the loss function in the training step

定义为:

$$e_{\text{RMSE}} \triangleq \sqrt{\frac{1}{2KL} \sum_{l=0}^L \sum_{k=1}^K [(\hat{\theta}_{k,l} - \theta_k)^2 + (\hat{\varphi}_{k,l} - \varphi_k)^2]} \quad (31)$$

其中 K 为目标个数, L 为蒙特卡罗试验次数, 设置为 1000。将方位角定义为 $\varphi = [\varphi_0, \dots, \varphi_{K-1}]^T$, 俯仰角为 $\theta = [\theta_0, \dots, \theta_{K-1}]^T$ 。 $\hat{\varphi}_{k,l}$ 和 $\hat{\theta}_{k,l}$ 分别是第 l 次蒙特卡罗试验对第 k 个目标的方位角和俯仰角估计值。

图5绘制了OMP、FFT、DNN-OMP、DNN-FFT、DNN-DANM、DNN-NLS等算法在不同信噪比下的DOA估计性能。从仿真结果可以看出,各算法的估计性能随着SNR的提高而提高,但由于互耦效应和反射失配的影响,在SNR大于30 dB的场景下,各算法均无法得到更优异的估计性能。在SNR=30 dB时,FFT算法的RMSE约为10°,使用DNN重构后可将DOA估计性能提高到7°。DNN重构后,OMP算法的DOA估计性能提高了约2°。此外,所提算法

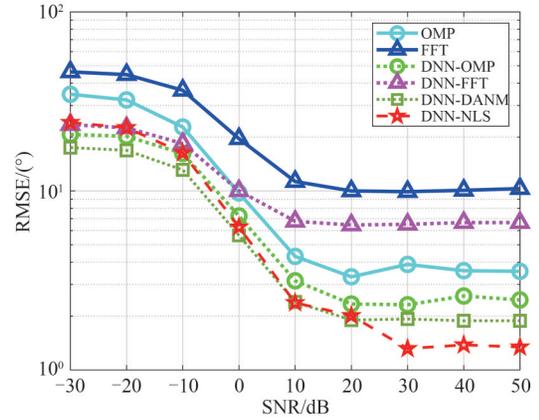


图5 不同信噪比下的DOA估计性能

Fig. 5 The DOA estimation performance with different SNRs

相比于DNN-OMP、DNN-FFT和DNN-DANM方法具有更好的DOA估计性能。这表明DNN重构步骤可以提高传统算法的DOA估计性能,而对重构后的信号用NLS算法进行估计可以得到更准确的估计角度。

图6分别绘制了在互耦效应和反射系数幅度较大场景下OMP、FFT、DNN-OMP、DNN-FFT、DNN-DANM、DNN-NLS等算法在不同信噪比下的DOA估计性能,其中互耦效应的分布为 $C \sim U[0.1, 0.8]$, 反射系数幅度为 $B_{m,n} \sim U[0.5, 1.5]$ 。与图5相比,在互耦效应和反射系数幅度较大场景下传统算法的DOA估计性能下降严重,但本文所提方法相对于其他算法依然能实现更优异的估计性能。这表明DNN重构步骤可以降低互耦和反射失配带来影响,大幅度提高算法的DOA估计性能。因此,在存在互耦效应和反射失配的RIS系统中,所提方法的估计性能

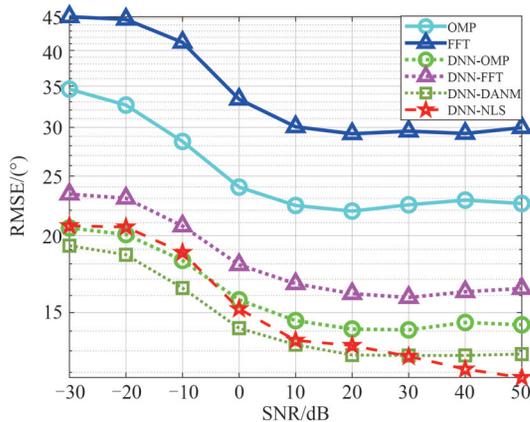
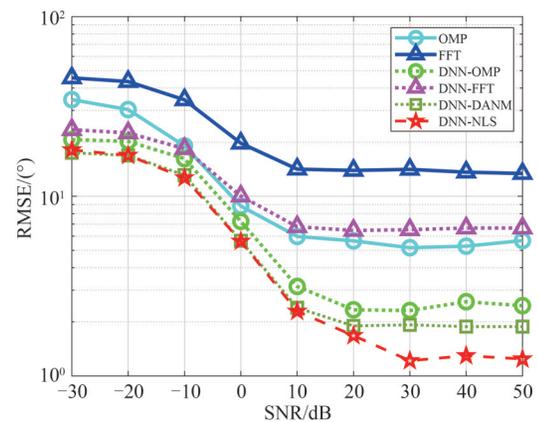
(a) 互耦系数为 $C \sim U[0.1, 0.8]$ (b) 反射系数幅度为 $B_{m,n} \sim U[0.5, 1.5]$

图6 存在互耦效应和反射失配时的DOA估计性能

Fig. 6 The DOA estimation performance with the mutual coupling effect and reflection mismatch

- 2012, 28(9): 1241-1247. (in Chinese)
- [15] ZHENG Yu, XIAO Yue, MA Zheng, et al. Neural network-based multi-DOA tracking for high speed railway communication systems[J]. IEEE Transactions on Vehicular Technology, 2022, 71(10): 11284-11288.
- [16] HUANG Hongji, YANG Jie, HUANG Hao, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system[J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8549-8560.
- [17] BASAR E. Reconfigurable intelligent surface-based index modulation: A new beyond MIMO paradigm for 6G [J]. IEEE Transactions on Communications, 2020, 68(5): 3187-3196.
- [18] CHEN Zhimin, CHEN Peng, ZHENG Le, et al. DNN-DANM: A high-accuracy two-dimensional DOA estimation method using practical RIS[EB/OL]. 2023: arXiv: 2309.13856. <https://arxiv.org/abs/2309.13856>.
- [19] CHEN Huayang, BAI Yechao, WANG Qiong, et al. DOA estimation assisted by reconfigurable intelligent surfaces[J]. IEEE Sensors Journal, 2023, 23(12): 13433-13442.
- [20] LIU Zhangmeng, ZHANG Chenwei, YU P S. Direction-of-arrival estimation based on deep neural networks with robustness to array imperfections[J]. IEEE Transactions on Antennas and Propagation, 2018, 66(12): 7315-7327.
- [21] CHEN Peng, CHEN Zhimin, ZHENG Beixiong, et al. Efficient DOA estimation method for reconfigurable intelligent surfaces aided UAV swarm[J]. IEEE Transactions on Signal Processing, 2022, 70: 743-755.
- [22] LIN Zhi, NIU Hehao, AN Kang, et al. Refracting RIS-aided hybrid satellite-terrestrial relay networks: Joint beamforming design and optimization[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(4): 3717-3724.
- [23] BELLAVIA S, GRATTON S, RICCIETTI E. A Levenberg-Marquardt method for large nonlinear least-squares problems with dynamic accuracy in functions and gradients [J]. Numerische Mathematik, 2018, 140(3): 791-825.
- [24] LIN Mingtuan, XU Ming, WAN Xiang, et al. Single sensor to estimate DOA with programmable metasurface [J]. IEEE Internet of Things Journal, 2021, 8(12): 10187-10197.

作者简介



郑乐男, 1987年生, 河北人。北京理工大学教授, 主要研究方向为雷达信号与信息处理、通信感知一体化。
E-mail: le.zheng.cn@gmail.com



赵钊皓 男, 2000年生, 山东人。北京理工大学雷达技术研究院硕士研究生, 主要研究方向为汽车雷达信号处理。
E-mail: 3120220808@bit.edu.cn



卢珊珊 女, 1992年生, 陕西人。西安电子工程研究所工程师, 主要研究方向为情报研究。
E-mail: lushanshan_416@163.com



陈鹏 男, 1989年生, 江苏人。东南大学副研究员, 主要研究方向为感知与抗干扰一体化技术。
E-mail: chenpengseu@seu.edu.cn



龙佳敏 女, 1996年生, 湖南人。北京理工大学雷达技术研究院在读博士研究生, 主要研究方向为汽车雷达信号处理。
E-mail: jiaminlong0548@163.com



胡雪瑶 男, 1990年生, 陕西人。北京理工大学副研究员, 主要研究方向为毫米波雷达系统设计与雷达信号处理技术等。
E-mail: xueyao.hu@qq.com

(责任编辑: 刘建新)