

基于 MAAM-LKN 模型的稀疏阵列双子阵 RCS 缩减方法

吉利霞¹, 陈毅乔², 任志刚², 曾浩^{3*}

(1. 重庆理工大学电气与电子工程学院, 重庆 400054; 2. 西南电子技术研究所, 四川成都 610036; 3. 重庆大学微电子与通信工程学院, 重庆 400044)

摘要: 阵列天线雷达散射截面(Radar Cross Section, RCS)等于天线散射单元因子与散射阵因子的乘积。通常采用稀疏阵列布局优化的方法,实现对散射阵因子峰值的抑制。近年来,基于深度学习的稀疏阵列 RCS 缩减方法有效提高了阵面的实时隐身性能。稀疏优化难以机械地实时拆除阵列中的天线,通常是通过负载匹配或自动相消的方法缩减无需工作的阵元 RCS 来实现,进而等效为“删除”阵元。但无论是负载匹配法,还是自动相消法,都无法使关闭阵元的 RCS 缩减至零,通常只能将其缩减到一个较小的值。然而,现有的基于深度学习的稀疏阵列 RCS 缩减方法都是针对关闭阵元 RCS 为零的场景,因此,已有方法不能适用于实际应用场景。为了解决该问题,提出了一种基于多模态与增强注意力机制的轻核网络(Light Kernel Network Based on Multimodal and Augmentation Attention Mechanism, MAAM-LKN)模型的稀疏阵列双子阵 RCS 缩减方法。具体而言,考虑到关闭阵元 RCS 通常不为零,引入了关闭阵元 RCS 因子,建立了稀疏阵列双子阵优化的问题模型与目标函数,利用 MAAM-LKN 模型同时优化工作子阵与关闭子阵的阵列布局,从而缩减工作子阵与关闭子阵的 RCS,最终实现整个阵面的 RCS 最小。此外,由于现有用于稀疏阵列 RCS 缩减的神经网络模型缺乏对重要信息的关注,在 MAAM-LKN 模型中,设计了增强注意力机制,根据特征的重要程度对特征进行加权,解决了特征传播过程中重点特征不够突出的问题,同时,为了提高模型的理解能力,引入多模态思想,实现更有效的重点特征提取与感知。仿真结果表明:在不同关闭阵元 RCS 因子下,双子阵优化与单子阵 RCS 优化相比,都能够有效提升稀疏阵列天线的 RCS 缩减性能,RCS 最大缩减值能够提升 2.72 dB 以上,RCS 平均缩减值能够提升 0.19 dB 以上;当关闭阵元 RCS 不为零时,MAAM-LKN 模型的准确率为 91.09%,RCS 缩减均值为 5.9 dB,均高于其他神经网络模型,同时保持模型复杂度相当。

关键词: RCS 缩减;关闭阵元 RCS 因子;稀疏阵列双子阵;深度学习;注意力机制;多模态

基金项目: 重庆理工大学科研启动基金(No.2025ZDZ025)

中图分类号: TN828

文献标识码: A

文章编号: 0372-2112(XXXX)XX-0001-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250961

RCS Reduction Method for Sparse Array Dual-Subarray Based on MAAM-LKN Model

JI Lixia¹, CHEN Yiqiao², REN Zhigang², ZENG Hao^{3*}

(1. School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China;

2. Southwest Electronic Technology Institute, Chengdu, Sichuan 610036, China;

3. School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

Abstract: The radar cross section (RCS) of an array antenna equals the product of the antenna scattering element factor and the array factor. Typically, sparse array arrangement optimization is used to suppress the peak value of the scattering array factor. In recent years, deep learning-based methods for sparse array RCS reduction have effectively improved the real-time stealth performance. However, sparse optimization cannot mechanically remove the elements from the array in real time. The load matching and active cancellation methods are used as the equivalent method to delete the passive elements, but these methods cannot reduce the RCS of passive elements to zero, they can only reduce it to a small value. Existing deep learning-based sparse array RCS reduction methods are designed for scenarios where the RCS of passive elements is zero. So, these existing methods unsuitable for practical applications. To address this issue, this paper proposes a sparse array dual-subarray RCS reduction method based on a light kernel network with multimodal and augmentation attention mechanism (MAAM-LKN). Specifically, considering that the RCS of passive elements is usually non-zero, a passive RCS factor of ele-

ment is introduced. A problem model and objective function for sparse array dual-subarray optimization are established, and the MAAM-LKN model simultaneously optimizes the array arrangements of both the active and passive subarrays. This reduces the RCS of both subarrays and ultimately minimizes the overall RCS of the array. Moreover, since existing neural network models for sparse array RCS reduction lack focus on important information, an augmented attention mechanism is designed in the MAAM-LKN model to weight features according to their importance. This addresses the issue of insufficient emphasis on key features during feature propagation. Additionally, to enhance the model's comprehension capability, the multimodal is introduced to achieve more effective extraction and perception of key features. Simulation results show that under different passive element RCS factor values, dual-subarray optimization can effectively improve the RCS reduction performance compared to single-subarray RCS optimization. The maximum RCS reduction value can be improved by more than 2.72 dB, and the average RCS reduction value can be improved by more than 0.19 dB. When the RCS of passive elements is non-zero, the MAAM-LKN model achieves an accuracy of 91.09% and an average RCS reduction of 5.9 dB, both higher than other neural network models, while maintaining comparable model complexity.

Keywords: RCS reduction; passive RCS factor of element; dual-subarray of sparse array; deep learning; attention mechanism; multimodal

Foundation Item(s): Research Start-up Foundation of Chongqing University of Technology (No.2025ZDZ025)

0 引言

电子战(或称电子对抗)就是以现代高新技术为背景的电子侦察与反侦察、电子干扰与反干扰、电子隐身与反隐身的综合战争。隐身技术在现代电子战中占有十分重要的地位。隐身性能通常由 RCS 定量描述^[1-2]。RCS 是一种虚拟面积,用于量化目标散射场的强度。RCS 缩减通过控制和最小化目标的雷达特征来提升军事目标的隐身性能^[3-4]。在飞行器的机载设备中,天线是总 RCS 的主要贡献者之一,因此缩减天线的 RCS 十分重要。天线是一种特殊的散射体,其散射场由两个部分组成:一是由天线的形状、材料及其周围环境决定的天线结构项散射场;二是负载与天线之间不匹配而产生的天线模式项散射场^[5-6]。

现代的飞行器上通常安装很多架天线,这些天线通常是由多天线组成的阵列天线。由于阵列天线的广泛应用,其 RCS 缩减成为隐身天线领域的研究热点。阵列天线 RCS 等于天线散射单元因子与散射阵因子的乘积^[7],其 RCS 缩减可以通过三种技术途径实现:隐身天线罩设计、减小散射单元因子和减小散射阵因子。文献[8-9]中通过使用频率选择表面的隐身天线罩来降低 RCS,但是隐身天线罩只能解决天线带外的 RCS 缩减问题。文献[10-12]通过改变结构来降低单元 RCS,但单元设计通常较难减小由阵列排布导致的散射阵因子峰值。

对于散射阵因子峰值的抑制,通常采用稀疏阵列来实现。稀疏阵列是在均匀分布的天线阵列中,有选择性地删除一定比例的阵元。文献[13]采用粒子群(Particle Swarm Optimization, PSO)算法排布天线单元以降低 RCS,但在线迭代优化算法时间成本较高,无法满足战场环境对实时优化的性能要求。相比于迭代优化算法,深度学习的实时性更好。文献[4]采用

轻核残差网络(Light Kernel Residual Network, LK-ResNet)对一个小规模稀疏阵列的 RCS 进行缩减,通过将非工作状态阵元连接匹配负载来等效删除阵元,从仿真结果可以看出非工作阵元无法实现完全匹配,即关闭阵元的 RCS 大于零,但是该文献是在关闭阵元的 RCS 为零的假设下建立的优化目标函数。文献[2]解决了大规模阵列的 RCS 缩减问题,为了使关闭阵元的模式项散射场与结构项散射场大小相等,相位相反,根据文献[12]将非工作阵元与环形器、移相器和放大器相连,但从其实验结果可以看出,很难实现关闭阵元的 RCS 相消为零,但是文献[2]也是在关闭阵元的 RCS 为零的假设下建立的优化目标函数。文献[14]提出了一种多任务网络,解决了多稀疏率阵列 RCS 缩减问题,同样采取了与文献[2]相同的关闭阵元方法。文献[15]利用迁移学习实现了不同频段的 RCS 缩减,也采用了与文献[2]相同的关闭阵元方法。通过对参考文献的分析可知,现有优化目标函数都是基于关闭阵元 RCS 为零这一理想假设,但无论通过负载匹配还是自动相消的方法,都很难做到让关闭阵元的 RCS 为零。因此,当关闭阵列 RCS 不为零时,已有的稀疏阵列 RCS 缩减优化模型不能很好地适用。

针对上述问题,本文提出基于 MAAM-LKN 模型的稀疏阵列双子阵 RCS 缩减方法。本文的主要贡献为:

(1) 针对关闭阵元 RCS 不为零的稀疏阵列,引入关闭阵元 RCS 因子,建立了基于双子阵的稀疏阵列 RCS 缩减优化模型。

(2) 提出 MAAM-LKN 模型,在该模型中,引入多模态思想,提高了模型特征表示能力,设计增强注意力机制,根据特征的重要程度对特征进行加权,解决了特征传播过程中重点特征不够突出的问题。

(3)对所提出的方法进行仿真和分析,仿真结果表明:当关闭阵元RCS不为零时,基于MAAM-LKN模型的稀疏阵列双子阵RCS缩减方法相比已有方法具有更高的RCS缩减性能。

1 系统模型

均匀矩形平面阵列如图1所示,阵列的规模为 $M \times N$, $m=0, 1, \dots, M-1$, $n=0, 1, \dots, N-1$,参考阵元位于坐标原点,阵元间距为 d 。俯仰角和方位角用 θ 和 φ 来表示,频率用 f 来表示。




图1 均匀矩形平面阵列模型

Figure 1 Uniform rectangular planar array model

参考阵元的RCS可以被表示为^[15]

$$\sigma_c(\Psi) = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|\mathbf{E}^s(\Psi)|^2}{|\mathbf{E}^i(\Psi)|^2} \quad (1)$$

其中, $\mathbf{E}^i(\Psi)$ 为入射场; $\mathbf{E}^s(\Psi)$ 为散射场; $\Psi=(\theta_r, \varphi_r, f_r)$, θ_r 为雷达波俯仰角; φ_r 为雷达波方位角; f_r 为雷达波频率; R 为参考阵元与雷达之间的距离。设结构项散射场为 $\mathbf{E}_s^s(\Psi)$,模式项散射场为 $\mathbf{E}_a^s(\Psi)$,则^[3]

$$\mathbf{E}^s(\Psi) = \mathbf{E}_s^s(\Psi) + \mathbf{E}_a^s(\Psi) \quad (2)$$

$\sigma_c(\Psi)$ 可以被重写为

$$\sigma_c(\Psi) = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|\mathbf{E}_s^s(\Psi) + \mathbf{E}_a^s(\Psi)|^2}{|\mathbf{E}^i(\Psi)|^2} \quad (3)$$

又根据 $\mathbf{E}_s^s(\Psi) = |\mathbf{E}_s^s(\Psi)| e^{j\phi_s^s(\Psi)}$ 和 $\mathbf{E}_a^s(\Psi) = |\mathbf{E}_a^s(\Psi)| e^{j\phi_a^s(\Psi)}$,式(3)可以被重写为

$$\sigma_c(\Psi) = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|\mathbf{E}_s^s(\Psi)| e^{j\phi_s^s(\Psi)} + |\mathbf{E}_a^s(\Psi)| e^{j\phi_a^s(\Psi)}|^2}{|\mathbf{E}^i(\Psi)|^2} \quad (4)$$

其中, $\phi_s^s(\Psi)$ 是 $\mathbf{E}_s^s(\Psi)$ 的相位, $\phi_a^s(\Psi)$ 是 $\mathbf{E}_a^s(\Psi)$ 的相位。

不同阵元的散射场会有波程差而导致的相位差,不考虑单元之间的差异和互耦,第 (m, n) 个阵元与参考阵元散射场的相位差为^[15]

$$\Delta\varphi_{m,n} = 2kd(m\cos\varphi_r\sin\theta_r + n\sin\varphi_r\sin\theta_r) \quad (5)$$

根据式(4)和式(5),得出天线阵列的RCS为^[15]

$$\sigma_{SA}(\Psi) = \sigma_c(\Psi) \left| \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} e^{j2kd(m\cos\varphi_r\sin\theta_r + n\sin\varphi_r\sin\theta_r)} \right|^2 \quad (6)$$

其中, $k = \frac{2\pi}{\lambda_r} = 2\pi \frac{f_r}{c}$ 为雷达波数; c 为真空中的光速。

稀疏优化难以机械地实时拆除阵列中的天线,通常是通过负载匹配^[4]或者是自动相消^[14-15]的方法缩减无需工作的阵元RCS来实现,进而等效为“删除”阵元。根据模式项散射场的定义可知,当负载匹配时,模式项散射场 $\mathbf{E}_a^s(\Psi)$ 为零,但是该方法未考虑结构项散射场,因此,此种方法下关闭阵元的RCS一定大于零。自动相消法通过对模式项散射场进行放大和移相,从而缩减单元RCS,关闭单元总的散射场可以表示为

$$\mathbf{E}^s(\Psi) = U(\Psi) e^{j\Delta\phi} \mathbf{E}_a^s(\Psi) + \mathbf{E}_s^s(\Psi) \quad (7)$$

其中, $U(\Psi)$ 为放大器放大倍数; $\Delta\phi$ 为移相器移相值。但是模式项与结构项散射场的估计误差会导致 $\mathbf{E}^s(\Psi) > 0$ ^[12]。

通过设计开关状态矩阵 \mathbf{G} 来表示所有阵元的开/关状态

$$\mathbf{G} = \begin{bmatrix} G_{0,0} & \cdots & G_{0,N-1} \\ \vdots & \ddots & \vdots \\ G_{M-1,0} & \cdots & G_{M-1,N-1} \end{bmatrix} \quad (8)$$

引入了关闭阵元RCS因子 μ ,工作阵元与关闭阵元的RCS之比为 $1:\mu$, μ 值的大小受天线类型与等效删除方法性能的影响,理论上,通过 μ 值的改变,开关状态矩阵可以适用于任意的稀疏阵列天线。如果 $G_{m,n} = \mu < 1$,则表示第 (m, n) 个阵元的状态是关闭,如果 $G_{m,n} = 1$ 则表示第 (m, n) 个阵元的状态是工作。建立双子阵优化模型,同时优化工作状态的子阵和关闭状态的子阵,基于双子阵的稀疏阵列天线RCS为

$$\sigma_{SA}(\Psi) = \sigma_c(\Psi) \left| \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} G_{m,n} e^{j2kd(m\cos\varphi_r\sin\theta_r + n\sin\varphi_r\sin\theta_r)} \right|^2 \quad (9)$$

根据阵列天线RCS等于散射单元因子乘以散射阵因子,稀疏阵列天线的RCS可以被重写为

$$\sigma_{SA}(\Psi) = \sigma_c(\Psi) \sigma_{sa}(\Psi) \quad (10)$$

其中,稀疏阵列的散射阵因子为

$$\sigma_{sa}(\Psi) = \left| \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} G_{m,n} e^{j2kd(m\cos\varphi_r\sin\theta_r + n\sin\varphi_r\sin\theta_r)} \right|^2 \quad (11)$$

在实际工作中,当系统对阵列增益要求小于满阵增益时,可以进行稀疏优化。如果阵列增益要求为 K ,则从阵列的 $M \times N$ 个阵元中选择 K 个工作阵元。稀疏率定义为

$$\rho = \frac{MN - K}{MN} \quad (12)$$

阵列孔径大小影响阵列的波束宽度,大阵列孔径能够在一定程度上降低波束宽度,提高分辨率^[16]。因此,在优化过程中,保持阵列四个角的阵元为工作

状态,即

$$G_{0,0}, G_{M-1,0}, G_{0,N-1}, G_{M-1,N-1} = 1 \quad (13)$$

工作阵元个数 K 的取值范围为

$$5 \leq K \leq MN - 1 \quad (14)$$

因此,所有可能的工作阵元的稀疏阵列布局总数 I 等于从 $MN - 4$ 个阵元中选出 $K - 4$ 个阵元的组合数

$$I = \frac{(MN - 4)!}{(K - 4)!(MN - K)!} \quad (15)$$

I 种工作阵元的布局对应 I 种关闭阵元的布局。稀疏阵列双子阵优化问题的核心为从所有可能的布局中选出使得阵面 RCS 最小的双子阵组合。将此问题建模为多分类任务,利用深度学习模型来选择最佳布局。建立带辐射性能约束的基于双子阵的稀疏阵列 RCS 优化目标函数为

$$\left\{ \begin{array}{l} \min_{\mathbf{G}} (\sigma_{\text{SA}}(\Psi, \mathbf{G})) \\ \text{s.t. } 0 \leq m \leq M - 1, \quad 0 \leq n \leq N - 1 \\ \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} G_{m,n} = K + (MN - K)\mu \\ G_{0,0}, G_{M-1,0}, G_{0,N-1}, G_{M-1,N-1} = 1 \end{array} \right. \quad (16)$$

其中, $\Psi = (\theta_r, \varphi_r, f_r)$ 为已知量。神经网络根据雷达信号的角度和频率信息,输出最佳的稀疏布局,使得阵列天线的 RCS 在雷达信号的角度和频率处被缩减,提高隐身性能,如图 2 所示,蓝色子阵为工作状态的子阵,灰色子阵为关闭状态的子阵。

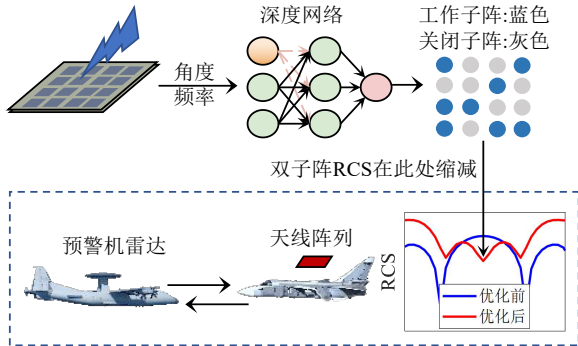


图2 整体框架示意图

Figure 2 Overall framework diagram

2 数据集生成

深度学习模型需要具备根据雷达信号的角度和频率信息输出最佳开关状态矩阵的能力,模型学习的对象就是雷达信号的角度频率与最佳开关状态矩阵之间的非线性关系。RCS 值的大小是由 Ψ 引起的相位差所决定,因此,本文将反射相位差矩阵^[14]作为模型的输入

$$\mathbf{T}(\Psi) = \begin{bmatrix} 1 & \dots & e^{j2kd(N-1)\sin\theta_r\sin\varphi_r} \\ \vdots & \ddots & \vdots \\ e^{j2kd(M-1)\sin\theta_r\cos\varphi_r} & \dots & e^{j2kdsin\theta_r[(M-1)\cos\varphi_r + (N-1)\sin\varphi_r]} \end{bmatrix} \quad (17)$$

但 $\mathbf{T}(\Psi)$ 是一个复矩阵,复数无法直接作为神经网络输入。由数学知识可知,一个复数能够唯一地用其实部和虚部表示,其相位则能够直观表示实部和虚部之间的关系。首先求出 $\mathbf{T}(\Psi)$ 实部

$$\mathbf{X}(1, :, :) = \text{Re}\{\mathbf{T}(\Psi)\} \quad (18)$$

其中, $\mathbf{X} \in \mathbb{R}^{3 \times M \times N}$ 是一个维度为 $3 \times M \times N$ 的实矩阵, $\mathbf{X}(1, :, :)$ 表示三维矩阵 \mathbf{X} 的第 1 层矩阵; $\text{Re}\{\cdot\}$ 表示取实部。然后求出 $\mathbf{T}(\Psi)$ 的虚部

$$\mathbf{X}(2, :, :) = \text{Im}\{\mathbf{T}(\Psi)\} \quad (19)$$

其中, $\mathbf{X}(2, :, :)$ 表示 \mathbf{X} 的第 2 层矩阵; $\text{Im}\{\cdot\}$ 表示取虚部。最后求出 $\mathbf{T}(\Psi)$ 的相位

$$\mathbf{X}(3, :, :) = \angle\{\mathbf{T}(\Psi)\} \quad (20)$$

其中, $\mathbf{X}(3, :, :)$ 表示 \mathbf{X} 的第 3 层矩阵; $\angle\{\cdot\}$ 表示取相位。所以, \mathbf{X} 是一个维度为 $3 \times M \times N$ 的实矩阵,将 \mathbf{X} 作为神经网络的输入样本。

设计好样本,还需要找到每个样本所对应的标签,利用样本-标签集对神经网络进行训练。式(8)定义了稀疏阵列的状态开关矩阵,本文将使得 RCS 在雷达波威胁角度和频率处最小的状态开关矩阵作为标签。采用遍历寻优的方法获取标签,所以本方法目前应用于小规模阵列。对于第 l 个样本, $l=1, \dots, L$, 首先根据稀疏率求出所有可能的开关状态矩阵,记为 $\{\mathbf{G}_1, \dots, \mathbf{G}_I\}$, $z=1, \dots, I$, 然后将 $\{\mathbf{G}_1, \dots, \mathbf{G}_I\}$ 中矩阵与角度频率依次代入优化目标函数公式(16)中,求出使得 σ_{SA} 最小的矩阵在 $\{\mathbf{G}_1, \dots, \mathbf{G}_I\}$ 中的索引值

$$\tilde{z}_l = \arg \min_{z=1, \dots, I} \{\bar{\sigma}_{\text{SA}}(\Psi_l, \mathbf{G}_1), \dots, \bar{\sigma}_{\text{SA}}(\Psi_l, \mathbf{G}_I)\} \quad (21)$$

开关状态矩阵 $\mathbf{G}_{\tilde{z}_l}$ 即为样本 Ψ_l 的标签。

数据集生成方法如算法 1 所示,根据式(17)~式(20)生成样本,根据式(21)生成标签,构建数据集。数据集生成后,随机将其分成训练集和测试集两部分,将 90% 的数据用于训练,剩余 10% 的数据用于测试。

3 MAAM-LKN 模型结构

已有的稀疏阵列 RCS 缩减神经网络都是基于关闭阵元 RCS 为零的理想假设,不能很好地适用于关闭阵元 RCS 不为零的稀疏阵列 RCS 缩减。为了实现稀疏阵列 RCS 更有效的缩减,本文提出了基于多模态与增强注意力机制的轻核网络(MAAM-LKN)模型,如图 3 所示。针对现有稀疏优化神经网络模型特征表示能力不足的问题,引入多模态思想^[17],将反射相位差

算法 1 反射相位差矩阵数据生成

输入: 阵列规模 $M \times N$, 工作阵元个数 K , 开关状态矩阵 $\mathbf{G}_{z,z=1,\dots,L}, \Psi_l, l=1,\dots,L$.

输出: 标签 $\mathcal{D} = \{\mathcal{X}, \mathcal{G}\}$

- 1: for $l \leq L$ do
- 2: $\mathbf{X}_l = [\text{Re}\{\mathbf{T}(\Psi_l)\} \text{Im}\{\mathbf{T}(\Psi_l)\} \angle\{\mathbf{T}(\Psi_l)\}]$
- 3: $\tilde{z}_l = \arg \min_{z=1,\dots,L} \{\bar{\sigma}_{\text{SA}}(\Psi_l, \mathbf{G}_1), \dots, \bar{\sigma}_{\text{SA}}(\Psi_l, \mathbf{G}_L)\}$
- 4: end for l
- 5: 构建样本矩阵 $\mathcal{X} = [\mathbf{X}_1; \dots; \mathbf{X}_L]$, 维度为 $L \times 3 \times M \times N$
- 6: 构建标签矩阵 $\mathcal{G} = [\mathbf{G}_{z_1}; \dots; \mathbf{G}_{z_L}]$, 维度为 $L \times M \times N$
- 7: 构建数据集 $\mathcal{D} = \{\mathcal{X}, \mathcal{G}\}$

矩阵的虚部和实部作为一个模态, 将相位作为另外一个模态。针对已有稀疏阵列模型对重要信息的关注不足和理解能力较弱的问题, 设计了增强注意力机制, 相比于传统的通道注意力机制^[18], 增强注意力机制保留了更多原始数据, 同时又实现了部分特征的增强, 原始数据的保留降低了模型的过拟合问题, 提高了模型的泛化能力。

MAAM-LKN模型的输入是反射相位差矩阵, 输出是预测的开关状态矩阵。定义网络的总层数为 $A, a=1, 2, \dots, A, \mathbf{Y}^{(a)}$ 为网络第 a 层的输出, 第 $a+1$ 层的输

入, $\mathcal{A}^{(a)}(\cdot)$ 为第 a 层网络运算, $\mathcal{A}^{(a_1-a_2)}(\cdot)$ 为网络第 a_1 层至第 a_2 层运算

$$\mathcal{A}^{(a_1-a_2)}(\mathbf{Y}^{(a_1-1)}) = \mathcal{A}^{(a_2)}\left(\mathcal{A}^{(a_3-1)}\left(\dots\mathcal{A}^{(a_1)}\left(\mathbf{Y}^{(a_1-1)}\right)\right)\right) \quad (22)$$

其中, a_1, a_2 为正整数且 $A \geq a_2 > a_1$ 。

将增强注意力模块看作一个整体层, MAAM-LKN模型各个层之间关系可以表示为

$$\mathbf{Y}^{(1)} = \mathcal{A}^{(1)}(\mathbf{X}) \quad (23)$$

$$\hat{\mathbf{G}} = \mathcal{A}^{(6-29)}\left(\mathcal{A}^{(2-1-5-1)}\left(\mathbf{Y}^{(1)}(3, :, :)\right), \mathcal{A}^{(2-2-5-2)}\left(\mathbf{Y}^{(1)}(1: 2, :, :)\right)\right) \quad (24)$$

其中, $\mathcal{A}^{(1,7,11,15,19)}$ 层都为增强注意力模块, $\mathcal{A}^{(2-1.2-2,5-1,5-2,10,14,18)}$ 层为卷积层, 卷积核大小为 1×1 , 输出通道数分别为 12, 24, 12, 24, 32, 64, 64。

MAAM-LKN模型使用交叉熵损失函数^[19], 在Torch中, 交叉熵损失函数内部包含了Softmax函数, Softmax函数将LK-ResNet模型的第22层的输出转化为类别预测分布, 即为预测列向量 $\hat{\mathbf{p}}_l$ 。构建维度为 $Z \times 1$ 的列向量 \mathbf{p}_l , 列向量 \mathbf{p}_l 只有第 \tilde{z}_l 个元素为 1, 其他元素为 0。假设样本总数为 L , MAAM-LKN模型的交叉熵损失函数为

$$\text{Loss} = -\frac{1}{L} \sum_{l=1}^L (\mathbf{p}_l)^T \ln \hat{\mathbf{p}}_l \quad (25)$$

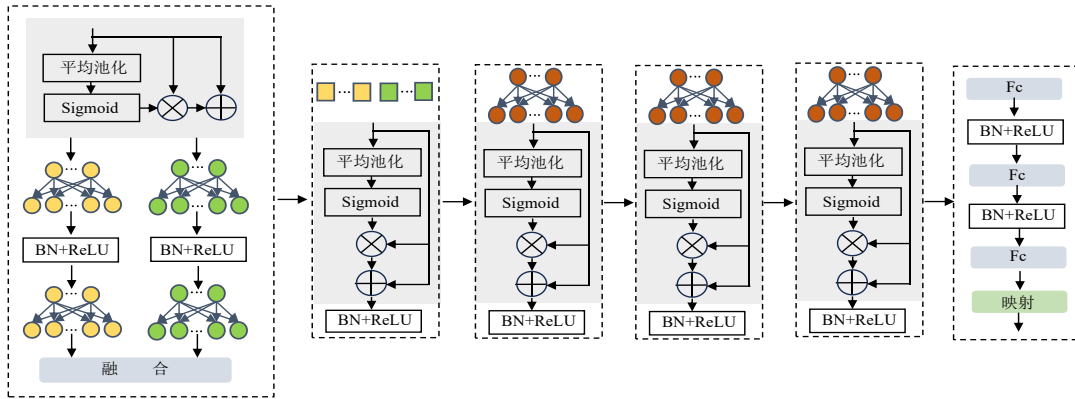


图3 MAAM-LKN模型结构

Figure 3 The architecture of MAAM-LKN model

4 仿真及分析

本节通过仿真对所提出基于MAAM-LKN模型的稀疏阵列双子阵RCS缩减方法有效性进行验证。首先, 仿真并分析了当关闭阵元RCS不为0时, 双子阵与单子阵优化的RCS缩减结果。然后仿真和分析了MAAM-LKN模型与其他模型的优化性能。如无特别说明, 仿真参数设置如下。

由于卫星通信天线安装在军用飞机的顶部, 其RCS一般对预警机雷达有意义, 而对地面雷达没有意

义。此外, 在实际战场情况下, 军用飞机与预警机的高度几乎相等, 且两者间距较远, 因此飞行器所提交的雷达波被认为是从水平方向入射的, 即由于阵列的对称性, 只需在 $[0, 45^\circ]$ 范围内优化方位角。在此范围内旋转开关状态矩阵即可得到其他方位角的开关状态矩阵。阵列规模为 4×4 。工作频率为 $f_c = 10$ GHz, 雷达信号频率为 $[9 \text{ GHz}, 10 \text{ GHz}]$, $\sigma_e = 1 \text{ m}^2$, 关闭阵元RCS因子 $\mu = 0.2$, 稀疏率 $\rho = 0.5$ 。数据集由算法1生成, MAAM-LKN模型的输入为反射相位差矩阵 \mathbf{X} , 输出为

开关状态矩阵 \mathbf{G} 。

所提出的 MAAM-LKN 模型在 Windows 服务器的深度学习平台 torch 上实现。Windows 服务器配置 3 块 Tesla T4 GPU, CPU 为 Intel Xeon Gold 5215。在训练中,使用了比随机梯度下降更稳定和有效的 Adam 优化器。训练批大小为 2048,学习率为 0.01,总训练次数为 200 次。

4.1 双子阵模型的 RCS 缩减结果

为了对比单子阵优化与双子阵优化的性能,基于 MAAM-LKN 模型分别进行单子阵优化和双子阵优化的仿真和分析。以雷达波频率 9.96 GHz,雷达波的来波角度 34.5° 为例,双子阵和单子阵^[4]优化输出的开关状态矩阵如图 4 所示。从图中可以看出:两种优化方法得到的开关状态矩阵四个角上的元素值为 1,即四个角上阵元为工作状态,满足式(9)中孔径约束要求;不同优化角度下输出的开关状态矩阵中工作阵元个数都为 8,满足稀疏率约束要求。




图 4 开关状态矩阵

Figure 4 Switch state matrices

图 4(a)和图 4(b)对应的稀疏阵列 RCS 曲线分别为图 5 中黄色线和紫色线,从图 5 可以看出:与满阵相比,在优化角度处,单子阵优化的稀疏阵列 RCS 缩减了 2.5 dB,双子阵优化的稀疏阵列 RCS 缩减了 5.48 dB,双子阵优化相比单子阵优化性能提升了 2.98 dB。仿真结果说明:基于 MAAM-LKN 模型的双子阵方法有效提升了非理想阵面的 RCS 缩减性能。

为了分析基于 MAAM-LKN 模型的双子阵优化效

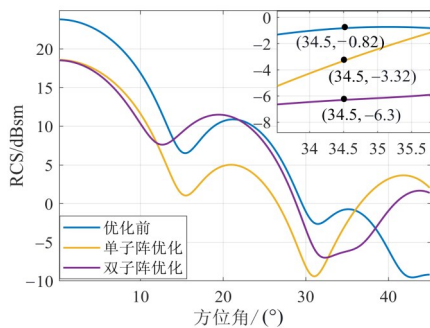


图 5 RCS 缩减结果

Figure 5 RCS reduction result

果,对单子阵和双子阵 RCS 缩减性能进行了仿真。首先,假设 $\mu=0.2$,得到不同工作阵元个数的单子阵和双子阵 RCS 缩减结果如图 6 所示,图 6(a)的横坐标为方位角,纵坐标为频段平均 RCS,表示的是不同方位角的频段平均 RCS;图 6(b)为图 6(a)的局部放大图;图 6(c)的横坐标是雷达波频率,纵坐标为角域平均 RCS,表示的是不同频率的角域平均 RCS 值,不同颜色的线表示不同的稀疏率。为了进一步对方法的有效性进行验证,又假设 $\mu=0.3$,得到了如图 7 所示的仿真结果。从图 6 和图 7 可以看出,相比单子阵方法,双子阵 RCS 缩减方法在不同稀疏率、不同角度、不同频率都能够更有效地缩减 RCS。仿真结果表明:当关闭阵元 RCS 不为 0 时,所建立的双子阵优化模型能够有效解决稀疏阵列的 RCS 缩减问题,提高阵面的隐身性能。


为了定量分析双子阵模型的有效性,表 1 给出了相比单子阵优化的 RCS 缩减的平均提升值和最大提升值。从表中可以看出:当 $\mu=0.2$ 时,所提出的方法在不同工作阵元个数下,平均 RCS 缩减均值能够提高 0.19 dB 以上,最大值缩减值高于 2.54 dB;当 $\mu=0.3$ 时,所提出方法在不同工作阵元个数下,平均 RCS 缩减均值能够提高 0.31 dB 以上,最大值缩减值高于 3.16 dB; μ 值越大,所提出的方法有效性越高。仿真结果表明:当关闭阵元 RCS 不为 0 时,所提出的方法通过改变参数 μ ,能够在理论上适用于任意的稀疏阵列天线 RCS 缩减。

4.2 MAAM-LKN 模型的性能

为了分析多模态与增强注意力机制对网络性能的影响,对无多模态和注意力机制的轻核网络、多模态轻核网络、基于多模态和注意力机制的轻核网络以及所提出的 MAAM-LKN 模型进行了仿真。图 8 为测试准确率随训练次数变化的仿真结果,从图中可以看出:设计的多模态与增强注意力机制能够有效提高模型的准确率。


为了定量分析多模态和增强注意力机制对模型性能的影响,表 2 给出了网络的测试准确率最大值和复杂度。从表中可以看出:所设计的多模态和增强注意力机制,在不增加模型复杂度的前提下,准确率提高了 0.82%。仿真结果表明:提出的多模态与增强注意力机制能够有效提高模型对重点特征的提取与感知能力,提升模型的性能,能够有效解决双子阵 RCS 缩减问题。

现有文献中, CNN、LK-ResNet 和 AM-FCSN 模型已被用于优化稀疏阵列,将 MAAM-LKN 模型的性能与这些稀疏优化网络在双子阵 RCS 缩减问题上的性能进行对比。为了使得这些模型更好地适应数据集,对模型的网络参数进行了轻微的调整,同时保持网络的整体结构不变。为了增加实验的多样性,还与



(a) Average RCS of frequency bands at different azimuth angles (b) Local magnification of (a) (c) Average RCS of angular domains at different frequencies
图6 不同工作阵元个数的单子阵和双子阵 RCS 缩减结果($\mu=0.2$)

Figure 6 The RCS reduction results of single and dual subarrays with different numbers of active array element ($\mu=0.2$)



(a) Average RCS of frequency bands at different azimuth angles (b) Local magnification of (a) (c) Average RCS of angular domains at different frequencies
图7 不同工作阵元个数的单子阵和双子阵 RCS 缩减结果($\mu=0.3$)

Figure 7 The RCS reduction results of single and dual subarrays with different numbers of active element ($\mu=0.3$)

表1 双子阵相比单子阵 RCS 缩减提升值 单位:dB

Table 1 RCS reduction of dual-subarray improvement value compared with single-subarray unit:dB

μ	K	双子阵相比单子阵 平均缩减值	双子阵相比单子阵 最大缩减值
0.2	7	0.19	3.09
	8	0.26	2.98
	9	0.20	2.54
	10	0.26	2.72
	11	0.19	2.73
0.3	7	0.30	3.16
	8	0.40	3.48
	9	0.38	3.00
	10	0.41	3.62
	11	0.31	3.58

RNN 和 LSTM 模型进行了比较,由于 RNN 和 LSTM 模型尚未应用于稀疏阵列优化问题,保留其主要结构,同时进行参数调整。图9为不同网络模型的测试准确率随训练次数变化的仿真结果。从图中可以看出所

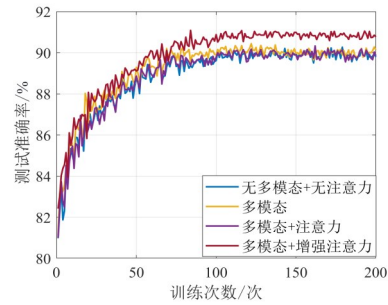


图8 测试准确率随训练次数变化的仿真结果

Figure 8 The simulation results of test accuracy with training epochs

表2 模型测试准确率和复杂度

Table 2 The test accuracy and complexity of the model

多模态	注意力 增强	准确率/%	复杂度	
			FLOPs/M	参数量/M
无	无	90.27	2.35	2.20
有	无	90.44	2.34	2.20
有	有/无	90.33	2.34	2.20
有	有/有	91.09	2.34	2.20

提出的双子阵优化模型 MAAM-LKN 的准确率最高。

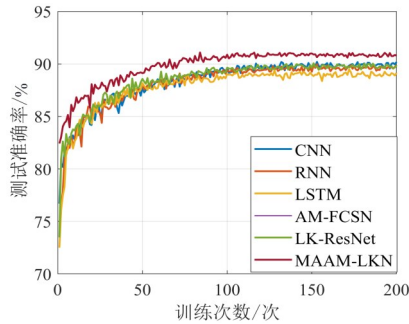


图9 测试准确率随训练次数变化的仿真结果

Figure 9 The simulation results of test accuracy with training epochs

为了定量地分析不同模型的性能,表3给出了不同网络的测试准确率最大值、RCS 缩减均值和复杂度。模型的准确率越高,输出正确标签的概率越高,由于这是一个概率问题,不同模型预测错误的样本可能不是同一个样本,无法对比各个模型对单个样本的 RCS 缩减结果,因此只能采用统计学的方法,对比 MAAM-LKN 模型与其他模型在大量测试样本上的 RCS 缩减均值。从表中可以看出:在复杂度相当的情况下,MAAM-LKN 模型具有最高的测试准确率,比准确率次优的 LK-ResNet 模型高 0.88%;与其他神经网络模型相比,MAAM-LKN 模型具有更高的 RCS 缩减均值,相比 LK-ResNet 模型均值提高了 0.1 dB,此数值虽然较小,但这是在所有测试样本上的均值,如果只是观测某个样本,数值差别会较大。仿真结果表明:当关闭阵元 RCS 不为 0 时,所提出的 MAAM-LKN 模型具有更高的测试准确率、更强的 RCS 缩减性能和较低的网络复杂度。

表3 神经网络的测试准确率、RCS 缩减均值和复杂度

Table 3 The test accuracy, average RCS reduction value and complexity of the neural networks

网络模型	准确率/%	RCS 缩减 均值/dB	复杂度	
			FLOPs/M	参数量/M
CNN ^[20]	90.19	5.79	2.75	2.39
RNN ^[21]	89.97	5.77	2.40	2.21
LSTM ^[22]	89.48	5.75	3.03	2.25
LK-ResNet ^[4]	90.21	5.80	2.39	2.21
AM-FCSN ^[2]	90.06	5.78	2.84	2.02
MAAM-LKN	91.09	5.90	2.34	2.20

5 结论

本文的研究目标是实现关闭阵元 RCS 不为零时稀疏阵列 RCS 有效缩减。提出的基于 MAAM-LKN 的双子阵优化方法实现了这一目标。针对关闭阵元 RCS 不为零的稀疏阵面,建立双子阵优化的问题模

型,同时缩减工作子阵与关闭子阵的 RCS,从而实现阵列 RCS 最小。MAAM-LKN 模型引入了多模态思想,将反射相位差矩阵的虚部和实部作为一个模态,将相位作为另外一个模态,并设计增强注意力机制,相比于通道注意力机制,增强注意力机制保留了更多原始数据,同时又实现了部分特征的增强,原始数据的保留降低了模型的过拟合,提高了模型的泛化能力。仿真结果表明,关闭阵元 RCS 不为零时,双子阵优化相比单子阵优化 RCS 缩减效果更好;与其他网络相比,MAAM-LKN 具有更高的分类精度、更优的 RCS 缩减性能和较低的复杂度。本文以卫星通信天线隐身场景为背景,对该方法进行了仿真验证。从理论上讲,该方法可以进一步推广到其他隐身场景,如卫星导航天线、机间链天线等天线的隐身。

参考文献

- [1] 徐鹏颖, 蔺卡宾, 韩宝庆, 等. 阵列天线电磁-结构-热耦合理论: 现在与未来[J]. 电子学报, 2022, 50(12): 2817-2853. Xu Pengying, Lin Kabin, Han Baoqing, et al. Electromagnetic-structural-thermal coupling theory for array antenna: Present and future[J]. Acta Electronica Sinica, 2022, 50(12): 2817-2853. (in Chinese)
- [2] Ji Lixia, Ren Zhigang, Chen Yiqiao, et al. Large-scale sparse antenna array optimization for RCS reduction with an AM-FCSN[J]. IEEE Sensors Journal, 2025, 25(3): 5782-5794.
- [3] Zhang Yixuan, Jiao Yongchang, Zhu Mingda, et al. Wide-band near-field RCS measurement techniques with improved far-field RCS prediction accuracies[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 8000404.
- [4] Ji Lixia, Mei Ke, Chen Yiqiao, et al. Radar cross section reduction of antenna array with LK-ResNet[J]. IEEE Antennas and Wireless Propagation Letters, 2023, 22(12): 2993-2997.
- [5] 涂建军, 马丁. 基于粒子群结构寻优的电磁隐身微网格超表面[J]. 电子学报, 2023, 51(11): 3262-3270. Tu Jianjun, Ma Ding. Electromagnetic stealth micro-grid metasurface based on particle swarm structure optimization[J]. Acta Electronica Sinica, 2023, 51(11): 3262-3270. (in Chinese)
- [6] Wang J, Choi C, Moore R. Precision experimental characterization of the scattering and radiation properties of antennas[J]. IEEE Transactions on Antennas and Propagation, 1982, 30(1): 108-112.
- [7] Elbir A M, Mishra K V. Joint antenna selection and hybrid beamformer design using unquantized and quantized deep learning networks[J]. IEEE Transactions on Wireless Communications, 2020, 19(3): 1677-1688.

- [8] Ha T D, Zhu Liang, Alsaab N, et al. Optically transparent metasurface radome for RCS reduction and gain enhancement of multifunctional antennas[J]. IEEE Transactions on Antennas and Propagation, 2023, 71(1): 67-77.
- [9] EL-Sewedy M F, Abdalla M A. A monostatic and bistatic RCS reduction using artificial magnetic conductor metasurface[J]. IEEE Transactions on Antennas and Propagation, 2023, 71(2): 1988-1992.
- [10] Yu Yufeng, Yu Weiliang, Xie Guotai, et al. Wideband RCS reduction of slot array antenna utilizing 3-D absorptive frequency-selective structure[J]. IEEE Antennas and Wireless Propagation Letters, 2022, 21(1): 64-68.
- [11] Zhang Shun, Yang Xuesong, Chen Bingjie, et al. Miniaturized wideband $\pm 45^\circ$ dual-polarized metasurface antenna by loading quasi-fractal slot[J]. IEEE Antennas and Wireless Propagation Letters, 2023, 22(4): 893-897.
- [12] Nakamoto N, Takahashi T, Fukasawa T, et al. RCS synthesis of array antenna with circulators and phase shifters and measurement method for deterministic RCS reduction[J]. IEEE Transactions on Antennas and Propagation, 2021, 69(1): 135-145.
- [13] Lu Bao, Gong Shuxi, Zhang Shuai, et al. Optimum spatial arrangement of array elements for suppression of gratinglobes of radar cross section[J]. IEEE Antennas and Wireless Propagation Letters, 2010, 9: 114-117.
- [14] Ji Lixia, Ren Zhigang, Chen Yiqiao, et al. RCS reduction for multiple-sparsity-rate arrays with a feature multitask network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(2): 3610-3625.
- [15] Ji Lixia, Chen Yiqiao, Ren Zhigang, et al. Transfer learning for RCS reduction of antenna arrays across arbitrary frequency bands[J]. IEEE Transactions on Antennas and Propagation, 2025, 73(10): 8104-8115.
- [16] 张玉洪, 保铮. 最佳非均匀间隔稀疏阵列的研究[J]. 电子学报, 1989, 17(4): 81-87.
Zhang Yuheng, Bao Zheng. Study of optimum thinning arrays by nonuniform spacings[J]. Acta Electronica Sinica, 1989, 17(4): 81-87. (in Chinese)
- [17] Han Wenqi, Geng Jie, Xu Zhengyi, et al. Multimodal heterogeneous hypergraph learning for incomplete multimodal semantic segmentation of remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 5639915.
- [18] Sun Kun, Dong Fuxuan, Liu Wenxin, et al. Hyperspectral image classification with spatial-spectral-channel 3-D attention and channel attention[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 4412314.
- [19] Zadeh S G, Schmid M. Bias in cross-entropy-based training of deep survival networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(9): 3126-3137.
- [20] Cheng Tianhao, Wang Buhong, Wang Zhen, et al. Lightweight CNNs-based interleaved sparse array design of phased-MIMO radar[J]. IEEE Sensors Journal, 2021, 21(12): 13200-13214.
- [21] Shi Yang, Ding Chenling, Li Shuai, et al. New RNN algorithms for different time-variant matrix inequalities solving under discrete-time framework[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(3): 5244-5257.
- [22] Fan Yuqi, Liu Jiahao, Ye Han, et al. TA-LSTM: A time and attribute aware LSTM for deep flight track clustering[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(5): 7047-7060.

作者简介



吉利霞 女, 1993年10月出生于河北省邢台市, 现为重庆理工大学讲师, 主要研究方向为阵列信号处理, 阵列RCS缩减与深度学习。
E-mail: jlx@cqut.edu.cn



陈毅乔 男, 1983年9月出生于四川省成都市, 现为西南电子技术研究所研究员, 主要研究方向为阵列天线与电磁场数值模拟。
E-mail: sccdycyq@163.com



任志刚 男, 1981年6月出生于黑龙江省佳木斯市, 现为西南电子技术研究所研究员, 主要研究方向为可重构天线与电磁场数值模拟。
E-mail: eric667@163.com



曾浩 男, 1977年11月出生于四川省泸州市, 现为重庆大学教授, 主要研究方向为阵列信号处理, 阵列RCS缩减与深度学习。
E-mail: haoz@cqu.edu.cn