



XXXX

基于注意力增强特征调制的高效三维天线辐射方向图 重构

周珂全¹, 余官定¹, 金敏玉², 雷志纯²

(1. 浙江大学信息与电子工程学院, 浙江 杭州 310027;

2. 华信咨询设计研究院有限公司, 浙江 杭州 310000)

摘 要: 针对无线通信仿真与网络规划中完整三维天线辐射方向图获取困难的问题, 提出了一种基于注意力增强特征调制的高效三维天线辐射方向图重构方法。设计了轻量化稳健损失函数, 以结构一致性约束替代现有深度学习方法的外部自编码器监督, 降低额外训练负担。同时, 引入双向交叉注意力与特征调制机制, 对水平与垂直切片特征进行动态融合, 从而显著提升全局重建的精度。此外, 基于 U-Net 架构进一步改进了神经网络, 在与基线同等参数量级下实现了更快的误差收敛和更高的重建精度。在多样化天线数据集上的仿真结果表明, 该方法在均方根误差与结构相似性指标上均显著优于传统解析方法与现有人工智能基线, 验证了该方法在天线辐射方向图重构方面的有效性。

关键词: 天线辐射方向图; 深度学习; 注意力机制; U-Net 网络

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.

Efficient 3D Antenna Radiation Pattern Reconstruction via Attention-Enhanced Feature Modulation

ZHOU Kequan¹, YU Guanding¹, JIN Minyu², LEI Zhichun²

1. College of Information Science and Electronic Engineering, Zhejiang University, Hangzhou 310027, China

2. Huaxin Consulting Design & Research Institute Co., Ltd., Hangzhou 310000, China

Abstract: To address the difficulty of acquiring complete three-dimensional (3D) antenna radiation patterns for wireless simulation and network planning, an efficient reconstruction method based on attention-enhanced feature modulation was proposed. A lightweight robust loss function was designed, where structural consistency constraints were used to replace external autoencoder-based supervision, thereby reducing additional training overhead. Meanwhile, bi-directional cross-attention and feature modulation mechanisms were introduced to dynamically fuse horizontal and vertical slice features, thereby improving global reconstruction accuracy. Furthermore, the standard U-Net architec-

收稿日期: 2026-05-18; 修回日期: 2026-07-09

通信作者: 雷志纯, leizc.hx@chinaccs.cn

基金项目: 国家自然科学基金资助项目 (No.62471434)

Foundation Items: The National Natural Science Foundation of China (No.62471434)



ture was refined to achieve faster error convergence and higher reconstruction accuracy under a comparable parameter budget. Extensive simulations on a diverse antenna dataset demonstrate that the proposed method consistently outperforms both traditional analytical methods and existing artificial intelligence (AI) baselines in root mean square error (RMSE) and structural similarity index (SSIM) metrics, confirming its effectiveness for antenna radiation pattern reconstruction.

Key words: antenna radiation pattern, deep learning, attention mechanism, U-Net

1 引言

三维 (three dimensional, 3D) 天线辐射方向图是表征天线空间能量分布特性的核心物理参数, 能够全面刻画天线在不同方位角和俯仰角下的辐射能力。其完整数据不仅对网络覆盖规划^[1]、无线信道仿真^{[2][3]}等基础应用至关重要, 也为数字孪生^{[4][5]}、低空通信^{[6][7]}等新兴场景提供了重要的基础支撑。随着无线网络向高频段、大规模天线和立体覆盖方向发展, 对高精度 3D 天线方向图的需求日益突出。然而, 在实际工程与天线产品交付中, 受限于全空间测量的昂贵成本与漫长周期, 天线厂商通常仅提供完整 3D 天线方向图的水平与垂直主平面的增益切片数据^[8]。因此, 如何仅凭稀疏的二维 (two dimensional, 2D) 主平面切片信息, 高精度、高效率地重建完整的 3D 天线方向图, 已成为低空通信等相关领域与工程应用中亟待解决的重要问题。

围绕上述问题, 3D 天线方向图重建技术主要历经了基于物理先验的解析插值与基于数据驱动的人工智能重构两个发展阶段。早期工作聚焦于解析插值算法, 旨在通过算术方法融合主平面数据以近似全空间增益分布^[9-14]。其中, 最朴素的对数域求和 (Summing) 算法将水平与垂直切片增益数值在对数域直接相加, 凭借极简的计算逻辑在天线的主瓣增益拟合中取得了可靠性能, 但在强方向性天线的旁瓣与背瓣区域误差显著。为突破这一局限, 文献^[9]中提出了加权求和 (Weighted Summing) 算法。该方法引入角距离依赖的权重函数, 若重建点距已知主平面越近,

则对该主平面分配越大的权重, 实现了可观的精度提升。此后, 文献^[12]中提出一种交叉加权 (Cross-Weighted) 算法, 将权重计算与已知切片的实数域增益值相耦合, 使插值结果能够还原更多全局细节。更进一步, 文献^[12]提出的改进版混合插值 (Hybrid) 算法创造性地将前述加权策略与朴素 Summing 算法相融合, 通过构建与主瓣能量强度相关联的动态调节因子, 兼顾了主瓣重建精度与全局细节的保真度, 取得了更均衡的拟合效果。

近年来, 深度学习技术的突破为 3D 天线方向图重建提供了全新范式。不同于传统由模型驱动的解析插值方法, 深度学习技术依赖数据驱动, 通过大量的已知样本来训练深度神经网络 (deep neural network, DNN), 使之学习数据中的深层联系, 从而在未知的样本上实现高保真的重建效果。其中, 以 U-Net 为代表的网络架构^{[15][16]}基于其多尺度特征提取的优势, 在图像分割与重建任务中展现出卓越性能, 成为该类问题的主流选择。受此启发, 文献^[8]提出一种基于 U-Net 架构的 3D 天线方向图重建方法, 仅需主平面切片数据作为输入即可在均方根误差 (root mean square error, RMSE) 与结构相似性 (structural similarity index, SSIM) 指标上显著超越传统解析基线, 并已被集成至商业软件中。

尽管上述研究取得了显著进展, 但其仍存在明显局限性。首先, 现有方法对已知先验信息的利用不足, 未对输入的主平面切片在物理空间上的正交相关性进行充分捕捉与利用, 导致网络在收敛效率与全局重建精度上仍有提升空间。其

次, 为提升重建结果的感知质量, 现有方案严重依赖外部预训练的自编码器以提取特征感知损失。这种设计不仅引入了额外的模型训练开销与显存负担, 还大幅提升了算法部署的复杂度, 难以满足轻量化应用需求。

针对上述局限, 本文提出一种基于注意力增强特征调制的高效三维天线辐射图重构方法。该方法首先基于样本数据分布对输入的主平面切片数据进行零均值 (Z-score) 标准化, 以提升训练的数值稳定性。随后构建了名为CutNet的主干神经网络模型, 其特点是具备一个跨切片先验提取结构以及一系列由注意力机制驱动的特征调制。该模型通过交叉注意力机制捕捉水平与垂直主平面切片间的相关性, 将其作为先验用于动态调制隐层特征, 从而有效提升模型的训练效率与全局重建精度。此外, 我们提出一种稳健的重建损失函数, 通过引入结构一致性正则项以提升重建感知质量, 从而彻底消除训练额外模型的开销。我们还对每一项损失分量引入指数滑动平均 (Exponential Moving Average, EMA) 归一化机制, 以自适应地调整训练过程中各分量之间的数值平衡, 进一步提升模型的收敛稳定性。大量仿真实验结果表明, 所提方法在RMSE与SSIM指标上均显著优于传统解析与现有深度学习基线, 兼具更高的训练效率与工程实用性。

2 系统模型

2.1 天线辐射方向图

在标准球坐标系下, 定义3D天线辐射方向图为功率增益函数 $G(\theta, \phi)$, 其单位为分贝各向同性增益 (decibels relative to isotropic, dBi), 其中俯仰角 $\theta \in [0, \pi]$, 方位角 $\phi \in [0, 2\pi)$ 。该函数表征天线在任意空间方向 (θ, ϕ) 上的辐射功率密度相对于理想无耗全向天线的分贝增益。

在此基础上, 完整3D天线方向图可进一步

由两个正交的2D主平面切片表征。其中水平方向图定义为包含主辐射方向的水平平面上的增益分布, 表示为

$$G_H(\phi) = G\left(\frac{\pi}{2}, \phi\right), \quad \phi \in [0, 2\pi). \quad (1)$$

垂直方向图定义为包含主辐射方向的垂直平面上的增益分布, 该平面由方位角为 $\phi=0$ 与 $\phi=\pi$ 的两个垂直半平面拼接而成, 映射为 $\theta \in [0, 2\pi)$ 上的增益分布, 表示为

$$G_V(\theta) = \begin{cases} G(\theta, 0), & 0 \leq \theta \leq \pi \\ G(2\pi - \theta, \pi), & \pi < \theta < 2\pi \end{cases}. \quad (2)$$

2.2 问题建模

在实际工程中, 通常仅能获取完整3D天线方向图的两个正交2D主平面增益数据^[15]。虽然这两个切片保留了天线在主辐射平面内的核心特征, 但天线非主平面上的三维空间辐射细节却完全缺失。本文所研究的3D天线方向图重构问题, 即在已知有限2D切片 $\{G_H(\phi), G_V(\theta)\}$ 的约束下, 建立映射关系 f_1 以高精度恢复完整的3D天线方向图 $G(\theta, \phi)$, 建模为

$$f_1: (G_H(\phi), G_V(\theta)) \rightarrow G(\theta, \phi). \quad (3)$$

为实现数值计算, 将连续角度域离散化为均匀采样网格。定义俯仰角采样点数 N_θ 与方位角采样点数 N_ϕ , 构建离散角度集合

$$\begin{cases} \Theta = \{\theta_i = i \cdot \Delta\theta \mid i = 0, \dots, N_\theta - 1\} \\ \Phi = \{\phi_j = j \cdot \Delta\phi \mid j = 0, \dots, N_\phi - 1\} \end{cases}, \quad (4)$$

其中步长

$$\Delta\theta = \frac{\pi}{N_\theta}, \quad \Delta\phi = \frac{2\pi}{N_\phi}. \quad (5)$$

在此离散化框架下, 完整3D天线方向图表示为增益矩阵 $\mathbf{G} \in \mathbb{R}^{N_\theta \times N_\phi}$, 水平切片 $\mathbf{g}_H \in \mathbb{R}^{N_\phi}$ 对应矩阵中 $\theta = \pi/2$ 处的行向量, 垂直切片 $\mathbf{g}_V \in \mathbb{R}^{2N_\theta}$ 由 $\phi=0$ 及与其对称 $\phi=\pi$ 两列按角度顺序拼接得到。从而, 式(3)中问题建模的离散化形式为

$$f_2: (\mathbf{g}_H, \mathbf{g}_V) \rightarrow \mathbf{G}. \quad (6)$$



2.3 评估指标

为量化3D天线方向图重建性能, 本文采用RMSE与SSIM^[17]作为核心评估指标。

RMSE衡量重建增益与真实增益在数值上的绝对偏差, 反映整体幅度精度, 值越小表示重建效果越好。其定义为

$$\text{RMSE} = \sqrt{\frac{1}{N_\theta \times N_\phi} \|\mathbf{G} - \hat{\mathbf{G}}\|^2}, \quad (7)$$

其中 $\hat{\mathbf{G}} \in \mathbb{R}^{N_\theta \times N_\phi}$ 为重建增益矩阵。

SSIM从亮度、对比度及结构三个维度评估重建方向图与真值的形态相似度, 在重建的感知质量评估上相对RMSE更具参考价值, 值越大(最大为1)表示结构相似度越高。其定义为

$$\text{SSIM}(\mathbf{G}, \hat{\mathbf{G}}) = \frac{(2\mu_{\mathbf{G}}\mu_{\hat{\mathbf{G}}} + C_1)(2\sigma_{\mathbf{G}\hat{\mathbf{G}}} + C_2)}{(\mu_{\mathbf{G}}^2 + \mu_{\hat{\mathbf{G}}}^2 + C_1)(\sigma_{\mathbf{G}}^2 + \sigma_{\hat{\mathbf{G}}}^2 + C_2)}, \quad (8)$$

其中 μ 和 σ 分别表示均值和标准差, σ_{xy} 表示协方差, C_1, C_2 为稳定常数。

3 基于注意力增强特征调制的重构算法

为实现映射 f_2 , 本文采用深度学习技术, 提出基于注意力增强特征调制的重构算法, 整体流程如图1所示。算法获取方向图主平面切片($\mathbf{g}_H, \mathbf{g}_V$)后, 首先对数据进行Z-score标准化预处理。随后, 标准化数据被送入算法的主干DNN模型CutNet进行处理, 所得输出经过逆归一化操作, 得到最终的方向图重建结果。CutNet模型的

训练依赖损失函数驱动, 最终收敛得到目标映射 f_2 。

3.1 数据预处理

针对目标方向图重构任务, 现有方法通常直接对输入的绝对增益值切片($\mathbf{g}_H, \mathbf{g}_V$)进行插值, 或先按最大辐射方向归一化为相对增益后再处理。然而, 不同天线样本之间的增益幅值与取值范围存在明显差异, 直接送入DNN容易因数值尺度不一致而影响训练稳定性。因此, 本文首先对数据进行Z-score标准化预处理。

具体地, 本文利用训练集统计量分别对输入切片($\mathbf{g}_H, \mathbf{g}_V$)和目标方向图 $\mathbf{G}$ 进行Z-score标准化。记对应统计量为 (μ_H, σ_H) 、 (μ_V, σ_V) 和 (μ, σ) , 则训练阶段的标准化形式为

$$\mathbf{g}_H = \frac{\mathbf{g}_H - \mu_H}{\sigma_H}, \mathbf{g}_V = \frac{\mathbf{g}_V - \mu_V}{\sigma_V}, \mathbf{G} = \frac{\mathbf{G} - \mu}{\sigma}. \quad (9)$$

测试阶段仍使用训练集统计量对输入进行相同变换, 并将网络预测结果逆变换回原始物理尺度后再计算评价指标。通过上述处理, 模型训练始终在尺度更稳定的标准化空间中进行, 而测试结果则恢复到绝对增益空间, 从而兼顾了数值稳定性与物理可解释性, 同时避免了使用测试集分布信息造成的数据泄漏。

3.2 CutNet模型构建

在完成数据预处理之后, 本小节进一步构建CutNet模型。如图2所示, CutNet模型由跨切片




图1 算法整体流程图




图2 CutNet 模型架构

先验提取、主干重构网络以及注意力驱动的特征调制三大核心结构组成，下面分别展开说明。

3.2.1 跨切片先验提取

模型首先通过两个并行的编码分支对输入切片 \$(g_H, g_V)\$ 进行初始表征，得到切片特征 \$(t_H, t_V)\$。随后，两路切片特征分别进入上下文分支与主干分支。

在上下文分支中，模型通过池化下采样与双向交叉注意力建模两种正交切片之间的全局耦合。其中，双向交叉注意力 \$\mathcal{A}_{H \rightarrow V}\$ 和 \$\mathcal{A}_{V \rightarrow H}\$ 的具体计算采用基于查询 (query, Q)、键 (key, K)、值 (value, V) 的多头注意力形式^[18]。在本文中，\$\mathcal{A}_{H \rightarrow V}\$ 的计算由水平分支特征构建查询 \$\mathbf{Q}_H\$，由垂直分支特征构建键和值 \$\mathbf{K}_V, \mathbf{V}_V\$。\$\mathcal{A}_{V \rightarrow H}\$ 则对称地由垂直分支构建查询 \$\mathbf{Q}_V\$，由水平分支构建键和值 \$\mathbf{K}_H, \mathbf{V}_H\$。具体地，双向交叉注意力分别计算为

$$\mathcal{A}_{H \rightarrow V} = \text{Softmax} \left(\frac{\mathbf{Q}_H \mathbf{K}_V^T}{\sqrt{d_k}} \right) \mathbf{V}_V, \quad (10)$$

$$\mathcal{A}_{V \rightarrow H} = \text{Softmax} \left(\frac{\mathbf{Q}_V \mathbf{K}_H^T}{\sqrt{d_k}} \right) \mathbf{V}_H, \quad (11)$$

其中 \$d_k\$ 表示键向量维度。两路交叉注意力输出再经上下文聚合映射 \$\mathcal{M}_c(\cdot)\$ 得到全局注意力向量 \$\mathbf{c}\$，为后续重构模块提供跨切片先验信息。

在主干分支中，模型对两路特征 \$(t_H, t_V)\$ 分别做维度拓展与堆叠，得到两路 2D 特征平面并拼接，形成主干输入特征 \$\mathbf{F}_0\$。

3.2.2 主干重构网络

与现有方法采用标准 UNet 架构作为主干重构网络不同，本文对 CutNet 的主干重构网络在各层统一引入批归一化 (batch normalization, BN) 层与高斯误差线性单元 (Gaussian error linear unit, GELU) 层组合，以增强训练稳定性并加速模型收敛。

具体而言，网络接收主干输入特征 \$\mathbf{F}_0\$ 后，先后通过四级编码模块 \$\mathcal{B}_e^1 \rightarrow \mathcal{B}_e^2 \rightarrow \mathcal{B}_e^3 \rightarrow \mathcal{B}_e^4\$ 实现多尺度特征语义提取。随后进入解码阶段，经上采样与解码模块序列 \$\mathcal{U}^3 \rightarrow \mathcal{B}_d^3 \rightarrow \mathcal{U}^2 \rightarrow \mathcal{B}_d^2 \rightarrow \mathcal{U}^1 \rightarrow \mathcal{B}_d^1\$ 逐级恢复空间细



节,并在每一级与对应编码特征执行跳跃连接融合。解码末端的特征经一级输出映射 $\mathcal{H}(\cdot)$ 完成通道整合,再由角域投影算子 $\mathcal{P}(\cdot)$ 映射到目标方向图网格,得到最终重构结果 $\hat{\mathbf{G}}$ 。

3.2.3 注意力驱动的特征调制

在上述主干网络构建完成后,本文进一步引入基于全局注意力向量 $\mathbf{c}$ 的特征调制机制。具体地,设计了一系列由注意力驱动的特征调制模块。其以全局注意力向量为输入,并输出与各编码/解码阶段对应的缩放与平移调制参数集合 $\{(\gamma_\ell, \beta_\ell)\}_{\ell=1}^L$ 。随后,这些调制参数被注入对应层级特征,以实现全局注意力对局部特征处理的逐层引导。借助该机制,跨切片先验信息可在多尺度特征处理路径中持续传递,从而提升方向图重建的一致性与表达能力。

3.3 损失函数设计

本小节进一步说明训练损失函数的设计。重建模型训练的核心目标,是在优化重建绝对误差的同时兼顾重建感知质量的提升。现有方法^[15]在训练环节引入外部预训练自编码器,通过附加特征一致性损失,约束模型重建结果与真值在中间特征空间中的一致性,从而提升重建感知质量。然而,此类方案会带来额外的模型训练与协同优化开销。与之不同,本文不再引入外部自编码器监督,而是在重建损失中直接引入结构一致性正则项,以同时约束数值误差与结构感知误差,即

$$\mathcal{L}_{\text{base}} = \mathcal{L}_{\text{RMSE}} + \lambda_s \mathcal{L}_{\text{SSIM}}, \quad (12)$$

其中

$$\mathcal{L}_{\text{RMSE}} = \sqrt{\frac{1}{N_\theta \times N_\phi} \|\mathbf{G} - \hat{\mathbf{G}}\|^2}, \quad (13)$$

$$\mathcal{L}_{\text{SSIM}} = 1 - \text{SSIM}(\hat{\mathbf{G}}, \mathbf{G}), \quad (14)$$

$\lambda_s > 0$ 为结构一致性正则项的权重系数。

然而,多项损失的组合可能引入数值不平衡问题。 $\mathcal{L}_{\text{RMSE}}$ 与 $\mathcal{L}_{\text{SSIM}}$ 的取值区间和波动尺度不同,直接线性加权易导致训练阶段梯度贡献失

衡。为此,本文采用基于EMA的损失归一化策略。具体地,设第 t 轮迭代的两项损失分别为 $\mathcal{L}_{\text{RMSE}}^{(t)}$ 与 $\mathcal{L}_{\text{SSIM}}^{(t)}$,则其EMA统计量更新为

$$\bar{\mathcal{L}}_{\text{RMSE}}^{(t)} = m \bar{\mathcal{L}}_{\text{RMSE}}^{(t-1)} + (1-m) \mathcal{L}_{\text{RMSE}}^{(t)}, \quad (15)$$

$$\bar{\mathcal{L}}_{\text{SSIM}}^{(t)} = m \bar{\mathcal{L}}_{\text{SSIM}}^{(t-1)} + (1-m) \mathcal{L}_{\text{SSIM}}^{(t)}, \quad (16)$$

其中 $m \in (0, 1)$ 为动量系数。归一化后的两项损失写为

$$\tilde{\mathcal{L}}_{\text{RMSE}}^{(t)} = \frac{\mathcal{L}_{\text{RMSE}}^{(t)}}{\bar{\mathcal{L}}_{\text{RMSE}}^{(t)} + \epsilon}, \quad \tilde{\mathcal{L}}_{\text{SSIM}}^{(t)} = \frac{\mathcal{L}_{\text{SSIM}}^{(t)}}{\bar{\mathcal{L}}_{\text{SSIM}}^{(t)} + \epsilon}, \quad (17)$$

最终优化目标为

$$\mathcal{L}^{(t)} = \tilde{\mathcal{L}}_{\text{RMSE}}^{(t)} + \lambda_s \tilde{\mathcal{L}}_{\text{SSIM}}^{(t)}. \quad (18)$$

4 仿真测试结果

4.1 数据集构建

为训练所提出的CutNet模型,本文基于MATLAB (R2024a)仿真平台构建了丰富的天线辐射方向图数据集,覆盖全向、半定向与强定向等多类天线辐射方向图。具体地,本文自MATLAB Antenna Toolbox的不同天线家族中选取基底天线类型,并在基底天线基础上进一步引入阵列增强与扰动,以增强样本多样性。其中,阵列类型包含线阵、圆阵与矩形阵,同时施加相位抖动、幅度抖动与间距抖动,以模拟实际中天线数据的采集误差。

所构建的完整数据集共包含10,000个样本。针对每个样本,除必要的水平/垂直切片与完整3D方向图信息之外,数据集还记录了每个样本的天线族标签、阵列增强变体标签、工作频率等元信息,用于后续模型训练与性能评估。

4.2 仿真设置

本文基于PyTorch仿真平台实现模型训练与评估。数据集按照9:1的比例划分训练集与测试集,即约9,000个训练样本与1,000个测试样本。实验环境搭载了一块Intel(R) Xeon(R) Platinum 8350C CPU,以及一张NVIDIA GeForce RTX

4090 显卡。训练阶段统一设置所有模型的学习率为、批大小为 16、训练轮数为 50，以保证不同模型间的可比性。

作为性能评估的参考，本文将所提算法与以下几个基线算法进行比较：

1. **patternFromAI[8]**：采用标准 UNet 架构进行 3D 方向图重建，并在训练中引入外部特征监督思想，作为当前深度学习路线的直接对照。

2. **Hybrid[12]**：将 Cross-Weighted 算法与 Summing 算法折中融合，作为传统解析基线

参照。

3. **Cross-Weighted[12]**：将权重计算与已知切片的实数域增益值相耦合，作为传统解析基线参照。

4. **Weighted Summing[9]**：基于主平面切片角距离权重对水平与垂直信息进行插值融合，作为传统解析基线参照。

5. **Summing**：直接对主平面切片增益进行对数域叠加，作为最朴素的解析基线参照。

所提 CutNet 的模型实现细节如表 1 所示，其

表 1 模型实现

模块名	内部层名	参数	激活函数/设置
水平切片编码器	$2 \times (\text{Conv1D} + \text{BN} + \text{GELU})$	$C = 32, K = 7, P = 3, S = 1$ $\rightarrow C = 32, K = 5, P = 2, S = 1$	GELU
垂直切片编码器	$2 \times (\text{Conv1D} + \text{BN} + \text{GELU})$	$C = 32, K = 7, P = 3, S = 1$ $\rightarrow C = 32, K = 5, P = 2, S = 1$	GELU
平均池化下采样	AvgPool1D + LN	$K = 8, S = 8$	/
水平切片多头注意力	MultiheadAttention	$E = 32, H = 4, D = 0.1$	$H \rightarrow Q, V \rightarrow KV$
垂直切片多头注意力	MultiheadAttention	$E = 32, H = 4, D = 0.1$	$V \rightarrow Q, H \rightarrow KV$
上下文聚合映射	FC + GELU + FC	$C = 128 \rightarrow C = 64$	GELU
一级编码调制参数生成器	FC	$C = 64$	/
一级编码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 32, K = 3, P = 1, S = 1$	GELU
一级最大池化	MaxPool2D	$K = 2, S = 2$	/
二级编码调制参数生成器	FC	$C = 128$	/
二级编码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 64, K = 3, P = 1, S = 1$	GELU
二级最大池化	MaxPool2D	$K = 2, S = 2$	/
三级编码调制参数生成器	FC	$C = 256$	/
三级编码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 128, K = 3, P = 1, S = 1$	GELU
三级最大池化	MaxPool2D	$K = 2, S = 2$	/
底层调制参数生成器	FC	$C = 512$	/
底层编码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 256, K = 3, P = 1, S = 1$	GELU
三级卷积上采样	TransConv2D	$C = 128, K = 2, P = 0, S = 2$	/
三级解码调制参数生成器	FC	$C = 256$	/
三级解码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 128, K = 3, P = 1, S = 1$	GELU
二级卷积上采样	TransConv2D	$C = 64, K = 2, P = 0, S = 2$	/
二级解码调制参数生成器	FC	$C = 128$	/
二级解码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 64, K = 3, P = 1, S = 1$	GELU
一级卷积上采样	TransConv2D	$C = 32, K = 2, P = 0, S = 2$	/
一级解码调制参数生成器	FC	$C = 64$	/
一级解码器	$2 \times (\text{Conv2D} + \text{BN} + \text{GELU})$	$C = 32, K = 3, P = 1, S = 1$	GELU
二维卷积输出映射	Conv2D	$C = 1, K = 1, P = 0, S = 1$	/
平均池化角域投影	AdaptiveAvgPool2d	$O = (361, 181)$	/



中LN表示层归一化 (layer normalization, LN), FC表示全连接 (fully-connected, FC) 层, C表示通道数, K表示卷积/池化核大小, P表示补零填充大小, S表示卷积/池化步长, E表示嵌入维度, H表示注意力头数, D表示Dropout 概率, O表示输出形状。

模型训练设置如表2所示。

4.3 系统级验证




图3 系统级方案的RMSE与SSIM性能对比

为与现有解析插值方法及AI重建基线保持一致, 本文从增益数值误差与方向图结构相似性两个角度评价重建质量,采用RMSE和SSIM作为核心评估指标。图3展示了所提方法与传统解析方法及现有人工智能 (artificial intelligence, AI) 基线在上述指标上的对比结果。从图中可以看出, 所提方法在重建绝对误差方面显著优于传统

表2 模型训练设置

参数	值
优化器	AdamW
学习率	4e-4
权重衰减系数	1e-4
学习率调度器	ReduceLROnPlateau (factor = 0.9, patience = 5)
随机数种子	42
结构一致性正则项权重系数	0.05
EMA 动量系数	0.95
训练轮数	50
批大小	16

解析基线，且性能分布相较于标准 UNet 基线更为集中。在感知质量评估方面，所提方法的 SSIM 指标也展现出明显优势，表明注意力增强特征调制机制能够有效捕捉水平与垂直切片间的空间相关性，从而提升全局重建的结构保真度。

图 4 呈现了在挑战性天线样本上各方法的重建效果可视化对比。可以观察到，传统解析方法在旁瓣与背瓣区域存在明显的增益偏差，而现有 AI 基线虽能改善主瓣拟合效果，但在细节重建上仍有不足。相比之下，所提方法能够更准确地还原复杂方向图的空间分布特征，尤其在低增益区域的细节保持上表现更为出色，验证了跨切片先验提取与特征调制策略的有效性。

进一步，图 5 与图 6 分别给出了该挑战性样本的主平面切片真值以及各方法重建得到的 3D 方向图可视化对比。可以观察到，在仅依赖两个正交切片作为约束的条件下，所提方法能够更稳健地推断非主平面区域的辐射特性，重建结果在全局绝对精度与感知结构一致性方面均表现更为出色。这得益于注意力增强特征调制机制对切片

间隐含空间关联的有效挖掘，使得模型能够以有限的先验信息驱动高保真的三维重构，展现出强大的泛化能力。

4.4 消融实验与复杂度分析

为验证所提方法中各核心模块的有效性，图 7 展示了不同消融方案在测试集上的 RMSE 收敛曲线对比，各方案含义如下：

1. UNet[8]：采用标准 UNet 架构作为主干重构网络的基线方法；
2. Z-score 标准化 (S1)：在 UNet 基础上引入 Z-score 数据标准化预处理；
3. S1+主干网络增强 (S2)：在 S1 基础上引入 BN+GELU 组合改进主干重构网络；
4. S2+稳健损失函数 (S3)：在 S2 基础上引入 RMSE 与 SSIM 组合损失及 EMA 归一化设计；
5. S3+注意力增强特征调制 (CutNet)：本文所提的完整方法，在 S3 基础上进一步引入跨切片注意力机制与特征调制；
6. CutNet w/o 注意力增强特征调制：在完整 CutNet 基础上移除跨切片注意力机制与特征




图 4 系统级方案在挑战性样本上的重建效果可视化对比




图5 挑战性样本上的主平面切片真值




图6 挑战性样本上的3D方向图可视化对比




图7 不同消融方案的训练收敛曲线

调制；

7. CutNet w/o 稳健损失函数：在完整 CutNet 基础上将损失函数替换为纯 L1 损失；

8. CutNet w/o 主干网络增强：在完整 CutNet 基础上去除 BN 层，并将 GELU 替换为修正线性单元（rectified linear unit, ReLU）；

9. CutNet w/o Z-score 标准化：在完整 CutNet 基础上移除 Z-score 数据标准化预处理，直接使用原始增益数据进行训练。

从图 7 (a) 中收敛曲线可以看出，各模块的引入均带来了重建性能的持续提升。相比 UNet 基线，仅引入 Z-score 标准化即可在训练初期加快收敛速度，验证了数据预处理对训练稳定性的重要作用。进一步，S2 曲线结果表明主干网络增强设计有效提升了网络的表达能力与收敛效率。随后，稳健损失函数的引入进一步加快模型收敛，这得益于 EMA 归一化策略改善了训练过程的数值稳定性。最终，完整 CutNet 方法在 50 个训练轮次后达到了最低的测试误差，充分验证了所提系统级方案在捕捉切片间空间相关性、提升全局重建精度方面的有效性。此外，CutNet 在整个训练过程中始终保持最快的收敛速度与最稳定的下降趋势，表明所提各模块之间存在显著的协同增强效应。

进一步地，图 7 (b) 从反向消融角度验证了完整 CutNet 中各模块的独立贡献。可以看出，移除注意力增强特征调制、主干网络增强或 Z-score 标准化后，模型的测试误差整体均高于完整 CutNet，说明上述模块分别在跨切片先验利用、网络表达能力提升和输入数值稳定化方面发挥了积极作用。其中，去除注意力增强特征调制后模型最终误差明显升高，进一步表明跨切片注意力与特征调制机制是提升全局重建精度的关键因素。去除稳健损失函数后的曲线与完整 CutNet 较为接近，说明在本数据集上网络结构设计对精度提升起主要作用；同时，完整 CutNet 在训练后期仍保

持更低或相近的误差水平，表明稳健损失函数可在不引入外部自编码器监督的前提下提供结构一致性约束，从而辅助提升训练稳定性与重建可靠性。

表3 不同方案的复杂度与性能对比

方案	参数量	50 轮训练耗时	RMSE (dB) ↓	SSIM ↑
CutNet	2.072 M	58.09 min	1.580	0.966
UNet	1.954 M	51.81 min	2.203	0.920

此外，表3对比了所提CutNet与UNet基线的模型复杂度与重建性能。在参数量方面，两者均处于约2M量级，表明所提架构改进并未显著增加模型容量。尽管引入跨切片注意力与特征调制机制使训练时长略有增加，但所提方法在性能上实现了显著跃升：RMSE较基线降低约28%，SSIM提升至0.966。这表明，CutNet以较小的计算与时间开销，换取了重建精度与结构保真度的实质性突破，充分验证了该方法在工程部署中兼顾高效率与高性能的优越性。

5 结束语

本文面向完整3D天线辐射方向图获取困难的问题，提出了一种基于注意力增强特征调制的高效重构方法。针对现有深度学习方案依赖外部自编码器且未显式建模切片间空间相关性的局限，本文设计了轻量化稳健损失函数，并引入双向交叉注意力与逐层特征调制机制，有效挖掘方向图主平面切片间的相关性。同时，通过优化UNet主干结构，并设计基于EMA归一化的组合损失策略，在参数量级相当的前提下显著提升了模型训练稳定性与收敛速度。多样化天线数据集上的仿真实验表明，所提方法在RMSE与SSIM指标上均显著优于传统解析基线与现有深度学习方案，兼具高重建精度与低训练开销。



周珂全 (2001-), 男, 学士, 浙江大学信息与电子工程学院博士生, 主要研究方向为信道知识图谱、环境感知通信、语义通信、面向物理层通信的深度学习。



余官定 (1980-), 男, 博士, 浙江大学信息与电子工程学院博士生教授, 主要研究方向为通信感知一体化、移动边缘计算/学习、面向无线网络的机器学习。



金敏玉 (1979-), 男, 学士, 华信咨询设计研究院有限公司技术发展部总经理, 主要研究方向为无线通信网络、企业架构方向规划咨询工作。



雷志纯 (1976-), 男, 学士, 华信咨询设计研究院有限公司高级工程师, 主要研究方向为数字孪生在通信行业中的应用。

参考文献:

- [1] Zhang J, Yang L, Ma Q, et al. M2M facilitated wireless network coverage management and real-time monitoring[C]//2014 IEEE Network Operations and Management Symposium (NOMS). Krakow, Poland: IEEE Press, 2014: 1-5.
- [2] 周航, 秦亚龙, 龙泽宇等. 基于三维传播建模与自适应遗传算法的低空通信基站配置优化[J]. 电信科学, 2026, 42(4): 187-204.
Zhou H, Qin Y, Long Z, et al. Optimization of low-altitude communication base station configuration based on three-dimensional propagation modeling and adaptive genetic algorithm[J]. Telecommunications Science, 2026, 42(4): 187-204.
- [3] Zhou K, Zhang G, Li H, et al. F4-CKM: Learning channel knowledge map with radio frequency radiance field rendering [J]. IEEE Transactions on Communications, 2026, 74: 5684-5700.
- [4] Alkhateeb A, Jiang S, Charan G. Real-time digital twins: Vision and research directions for 6G and beyond[J]. IEEE Communications Magazine, 2023, 61(11): 128-134.
- [5] Lin X, Kundu L, Dick C, et al. 6G digital twin networks: From theory to practice[J]. IEEE Communications Magazine, 2023, 61(11): 72-78.
- [6] 丁旭辉, 卢琦, 张园园等. 面向低空经济的通信技术综述[J]. 南京航空航天大学学报(自然科学版), 2025, 57(6): 1026-1045.
Ding X, Lu Q, Zhang Y, et al. Review on communication technologies for low-altitude economy[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2025, 57(6): 1026-1045.
- [7] 殷哲. 低空通信网络优化研究[J]. 电信科学, 2026, 42(1): 211-220.
Yin Z. Research on optimization of low-altitude communication networks[J]. Telecommunications Science, 2026, 42(1): 211-220.
- [8] DiMeo P J, Sivaramakrishnan S, Iyer V. AI-based 3D antenna pattern reconstruction[C]//2024 IEEE International Symposium on Antennas and Propagation and INC/USNC-URSI Radio Science Meeting (AP-S/INC-USNC-URSI). Firenze, Italy: IEEE Press, 2024: 1-2.
- [9] Gil F, Claro A R, Ferreira J M, et al. A 3-D extrapolation model

- for base station antennas' radiation patterns[C]//Gateway to 21st Century Communications Village. VTC 1999-Fall. IEEE VTS 50th Vehicular Technology Conference (Cat. No. 99CH36324). Amsterdam, Netherlands: IEEE Press, 1999, 3: 1341-1345.
- [10] Gil F, Claro A R, Ferreira J M, et al. A 3D interpolation method for base-station-antenna radiation patterns[J]. IEEE Antennas and Propagation Magazine, 2002, 43(2): 132-137.
- [11] Allard R J, Werner D H. The model-based parameter estimation of antenna radiation patterns using windowed interpolation and spherical harmonics[J]. IEEE Transactions on Antennas and Propagation, 2003, 51(8): 1891-1906.
- [12] Vasiliadis T G, Dimitriou A G, Sergiadis G D. A novel technique for the approximation of 3-D antenna radiation patterns [J]. IEEE Transactions on Antennas and Propagation, 2005, 53 (7): 2212-2219.
- [13] Petrita T, Ignea A. A new method for interpolation of 3D antenna pattern from 2D plane patterns[C]//2012 10th International Symposium on Electronics and Telecommunications. Timisoara, Romania: IEEE Press, 2012: 393-396.
- [14] Leonor N R, Caldeirinha R F S, Sánchez M G, et al. A three-dimensional directive antenna pattern interpolation method[J]. IEEE Antennas and Wireless Propagation Letters, 2015, 15: 881-884.
- [15] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention (MICCAI). Munich, Germany: Springer, 2015: 234-241.
- [16] Siddique N, Paheding S, Elkin C P, et al. U-Net and its variants for medical image segmentation: A review of theory and applications[J]. IEEE Access, 2021, 9: 82031-82057.
- [17] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [18] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems (NIPS). Long Beach, CA, USA: Curran Associates, Inc., 2017: 5998-6008.