

# 基于对抗神经网络的反射面天线单输入口径场相位恢复方法\*

张 杨<sup>1</sup> 项斌斌<sup>1†</sup> 王 伟<sup>2</sup> 林上民<sup>3</sup> 崔汉伟<sup>1</sup> 郑天祥<sup>1</sup> 周建平<sup>1</sup> 何大林<sup>4</sup>

(1 新疆大学智能制造现代产业学院 乌鲁木齐 830011)

(2 西安电子科技大学机电工程学院 西安 710119)

(3 中国科学院西安光学精密机械研究所 西安 710119)

(4 中国科学院新疆天文台 乌鲁木齐 830011)

**摘要** 微波全息测量技术在反射面天线表面测量中广泛应用,其中相位恢复方法因其不需要额外专门设备而广泛应用于射电望远镜的面形校准.该方法通过天线远场强度数据,通常利用一定的反演算法通过口径场与远场数据迭代获取近似口径场相位的过程.为了提高解算效率,采用深度学习技术,基于条件生成对抗网络(Conditional Generative Adversarial Network, CGAN)方法设计了一种模型用于在单输入远场幅值下解决反射面天线口径场相位恢复的问题.基于该模型的相位恢复方法放弃了传统方法对先验知识的依赖以及耗时的迭代过程.在原来CGAN的损失函数中,结合了引入均方误差(Mean Square Error, MSE)和结构相似性指数(Structural Similarity Index Measure, SSIM)损失函数,以优化网络训练,提高相位恢复精度.验证表明,CGAN网络对泊松噪声具有鲁棒性,可用作相位恢复过程中的降噪工具.CGAN框架不仅提升了相位恢复精度,降低了计算复杂度,而且有助于解决傅里叶成像系统中的相位恢复问题,该方法还可用于其他领域的位相误差测量.

**关键词** 技术: 相位恢复, 方法: 数值, 方法: 数据分析

中图分类号: P111; 文献标识码: A

## 1 引言

在通信系统的组成部分中,射电望远镜的天线起着至关重要的作用.天线口径效率受反射面表面形状精度的影响,由于制造误差及重力等环境载荷引起的结构变形,天线的表面形状将偏离理想抛物面导致天线效率降低.为了保证天线效率,需要对天线反射面精度进行校准,测量反射表

面偏差,然后重新调整面板位置提供反射面形状精度以改善性能<sup>[1]</sup>.随着射电望远镜设计的不断进步,天线的直径不断增大,工作频率也不断提高,这对天线表面的精度提出了更高的要求.因此为了保持和提升天线的电性能,对其表面进行精确的测量和校准显得尤为重要.

20世纪80年代工业测量系统开始引入天线测量领域<sup>[2]</sup>.这些测量系统根据所采用的传感器类型,

2025-01-21收到原稿, 2025-04-08收到修改稿

\*新疆维吾尔自治区自然科学基金项目(2023D01C22), 国家自然科学基金项目(12363011、52275270), 新疆维吾尔自治区天池英才计划和自治区优秀博士后项目资助

† [xiangbinbin031@163.com](mailto:xiangbinbin031@163.com)

分别采用经纬仪法、摄影测量法等不同的测量技术. 在经纬仪法中, 利用高精度电子经纬仪, 基于空间角度测量技术实现对天线的非接触式测量. 但随着测量口径面积的增大, 需要手动设置更多的标识点, 增加了测量所需的时间和人工. 摄影测量法采用单台或数台高精度测量相机, 依据交会测量原理进行快速且无接触的测量. 这种方法同样需要人工布置大量的标识点, 其数量随着口径面积的增大而显著增加, 从而需要较多的时间投入.

20世纪80年代起, 一系列中大型毫米波和亚毫米波射电望远镜陆续投入使用. 上述传统的测量方法在精度上已趋于极限. 因此微波全息技术在测量天线表面精度方面的应用日益增多. 该技术基于射电望远镜天线口径场分布与远场方向图之间的傅里叶变换关系, 发展出一套测量体系. 根

据相位获取方式的不同, 微波全息技术可分为相位干涉全息法和相位恢复全息法两大类. 图1所示为相位干涉全息示意图, 该技术通过观测强射电源或地球同步卫星, 能够精确测量射电望远镜的复远场方向图<sup>[3]</sup>. 在此测量过程中, 参考天线接收到的卫星信标信号被送入全息接收机的参考通道, 而待测天线接收到的信号则充当微波全息接收机的测量信号. 在测试过程中, 参考天线固定不动, 持续对准卫星, 而待测天线则调整其方位或俯仰角度. 利用幅相接收机, 记录天线在各个位置上的幅度和相位数据, 进而得到待测天线的远场幅度和相位方向图. 通过傅里叶变换, 可以从这些数据中推导出天线的口径场分布, 包括天线口径上各点的电场幅值和相位信息, 基于口径场相位的分析结果, 可以确定天线表面与理想几何形态之间的偏差.

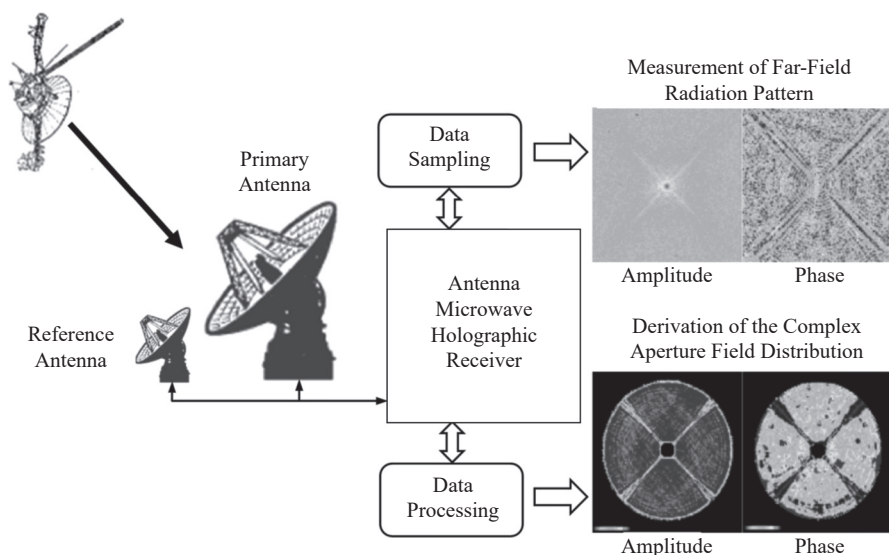


图 1 相位干涉全息示意图

Fig. 1 Schematic diagram of phase interference hologram

相位恢复全息技术不需要天线辐射场的相位, 而是利用射电望远镜的接收机进行测量. 在获得远场幅度数据后, 通过迭代算法来获得相位信息. 单幅值输入的迭代相位恢复算法起源于1972年Gerchberg提出的GS (Gerchberg-Saxton)算法, 该算法能够逆向推导出天线口径场的相位分布. 然而其算法的收敛性受到初始值选择的影响, 并依

赖于一定的先验知识<sup>[4]</sup>. 在GS算法之后, 为了降低对初始值选择的依赖性, 发展出了基于多幅值的GS改进算法, 如Misell算法. Misell算法通过采用多个远场幅值分布和预设的相位初始值, 经过多次迭代逐步接近真实的相位值. Misell算法在处理相位恢复问题时, 能够灵活调整梯度, 减少陷入局部最小值的可能性<sup>[5-8]</sup>. 这一方法已经在日本UDSC

(Usuda Deep Space Center) 64 m和紫金山天文台青海观测站13.7 m天线面形精度检测中展现了良好的效果<sup>[9-10]</sup>. 然而Misell算法的初值选择依然对算法性能有着显著的影响, 不恰当的初值会导致算法收敛速度缓慢或陷入局部最小值. 此外Misell算法在迭代过程中需要处理多个远场幅值分布, 增加了数据处理的复杂性<sup>[11]</sup>.

随着人工智能的发展, 深度学习在相位恢复中得到了广泛的应用. 2021年, Tong等人开发了1FPRNetV1 (Fourier Phase Retrieval Network version 1)网络, 其网络可以通过单远场衍射图实现相位恢复, 相比GSF (Gerchberg-Saxton-Fienup)算法, 其恢复相位效果更准确、更快速<sup>[12]</sup>, 也为本文的思路提供了启发. 生成对抗网络(Generative Adversarial Network, GAN)的改进网络—条件生成对抗网络(Conditional Generative Adversarial Network, CGAN), 引入了替代噪声的条件, 使其网络稳定性更优异, 同时保留了GAN的优点. 该模型也引起了神经网络领域的广泛关注, 并不断得到改进<sup>[13-14]</sup>. 2018年, Tang在无线电网络的自动调制分类工作中, 利用GAN生成器以扩大数据集并进行分类, 提高了分类准确率<sup>[15]</sup>. 2024年, Zou等人利用GAN来应对通信速率的逐渐提升和通信场景的复杂化带来的一些问题, 例如复杂信道生成、高维信道估计以及实际信号获取不足等, 结果认为GAN能够突破传统通信技术的瓶颈. 证明了GAN具有卓越的非线性拟合能力, 在数据生成、数据处理等方面发挥作用<sup>[16]</sup>.

针对现在单输入相位恢复算法GS法存在的对于选择初值敏感的问题, 基于深度学习技术的思想, 提出了一种基于CGAN的口径场相位恢复框架, 使用深度学习技术用于学习相位恢复算法中由远场幅值得到口径场相位的这种输入输出关系, 从而实现数据驱动的口径场相位恢复. 最终可以使用卷积网络在单输入远场幅值下恢复出反射面天线口径场相位, 对比传统方法能快速恢复口径场相位且能够避免对于先验知识的依赖. 另外GS算法在迭代过程中, 每一步的更新都依赖于前一步的结果. 如果输入数据中存在噪声, 这些噪声会在迭代过程中累积和放大, 导致最终恢复的相位分布偏离真实值. 而深度学习的端到端的训练

方式, 直接从输入数据到输出结果进行优化. 这种优化方式可以更好地利用数据中的信息, 减少中间环节的误差累积.

## 2 单输入相位恢复算法原理

### 2.1 单输入相位恢复迭代算法原理

单输入相位恢复迭代算法仅通过单幅远场强度图, 逐步逼近口径场相位分布. GS算法是单输入相位恢复迭代算法最具代表性的方法之一, 以其简洁性和有效性在相位恢复领域得到广泛应用.

如图2所示, GS算法是基于迭代思想的相位恢复算法. 其核心思想是在已知远场强度分布的条件下, 通过在远场和口径场之间反复迭代, 使运算最终收敛. 其迭代过程包括正向快速傅里叶运算(Fast Fourier Transform, FFT)和逆快速傅里叶运算(inverse FFT, iFFT), 设在第 $k$ 次迭代中, 将口径场通过FFT计算得到远场分布, 如下式:

$$T_{\text{far}}(u, v) = \mathcal{F}\{T_{\text{ap}}(x, y)\} = A \exp[i\psi(u, v)], \quad (1)$$

其中 $T_{\text{far}}(u, v)$ 表示天线远场分布,  $u$ 、 $v$ 分别表示天线远场上的横向和纵向坐标,  $T_{\text{ap}}(x, y)$ 表示天线口径场分布,  $x$ 、 $y$ 分别表示天线口径面上的横向和纵向坐标,  $\psi(u, v)$ 表示远场相位,  $A$ 表示远场幅值,  $\mathcal{F}\{T_{\text{ap}}(x, y)\}$ 表示口径场的傅里叶变换. 口径场傅里叶之后, 得到的远场 $T_{\text{far}}$ 保留相位, 用测量得到的远场幅值 $I$ 形成新的天线远场, 然后反向傅里叶计算得到天线口径场 $T_{\text{ap}}'$ , 如下式:

$$T_{\text{ap}}'(x, y) = \mathcal{F}^{-1}\{T_{\text{far}}(u, v)\} = \mathcal{F}^{-1}\{I \exp[i\psi(u, v)]\}, \quad (2)$$

其中 $\mathcal{F}^{-1}\{T_{\text{far}}(u, v)\}$ 表示对远场进行逆傅里叶计算, 计算每次傅里叶变换出的远场幅值与实际幅值的RMS (Root Mean Square):

$$\text{RMS}_{\text{far}} = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N [|T_{\text{far}}(i, j)| - |T_{\text{far\_real}}(i, j)]^2}{M \times N}}, \quad (3)$$

若前后两次RMS之差小于 $10^{-8}$ , 即:

$$\text{RMS}_{\text{far}}(k) - \text{RMS}_{\text{far}}(k-1) < 10^{-8}, \quad (4)$$

则迭代停止, 否则继续迭代, 直到满足收敛条件.

式中  $T_{\text{far}}$  为迭代过程中获得的远场幅值,  $T_{\text{far\_real}}$  为观测的远场幅值,  $M \times N$  为远场的数据点数. 此算法目标函数即口径场相位的RMS可以定义为:

$$\text{RMS}_{\text{ap}} = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N [\varphi_{\text{ap}}(i, j) - \varphi_{\text{ap\_real}}(i, j)]^2}{M \times N}}, \quad (5)$$

其中  $\varphi_{\text{ap}}$  为迭代过程中获得的口径场相位,  $\varphi_{\text{ap\_real}}$  为设置的口径场相位. 此迭代算法需要多次迭代才能实现良好的收敛并得到较高精度的恢复结果.

此外GS算法的结果部分依赖于迭代优化过程中所需的原始值. 当使用随机的相位或设置零初值作为初始解时, GS算法一般需要多次迭代才能收敛, 甚至由于遇到局部解而陷入停滞. 因此迭代算法的计算速度和收敛性是一个重要的问题, 基于深度学习的方法通过其强大的非线性映射能力、多层抽象表示、自动特征提取和端到端学习, 为解决非线性关系提供了新的途径, 也能解决在相位恢复时面临的计算速度和收敛性问题.

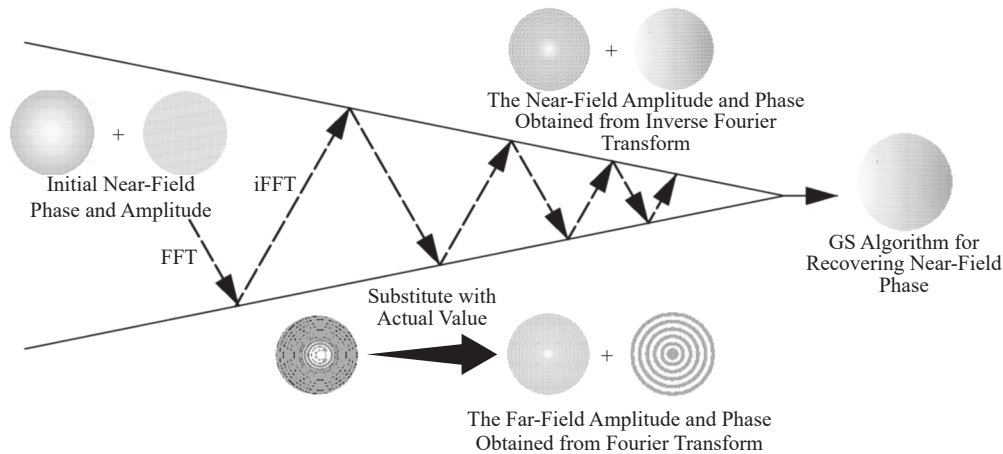


图 2 GS迭代算法示意图

Fig. 2 GS iterative algorithm schematic diagram

## 2.2 基于条件生成对抗网络的口径场相位恢复原理

对于相位恢复问题, 为了使用网络模型映射远场幅值与口径场相位之间的非线性关系, 可以利用卷积层的神经网络捕捉数据局部特征的能力, 通过非线性激活函数实现输入与输出间的复杂映射. 如图3所示, 使用网络模型构建远场幅值与口径场相位恢复之间的直接联系, 避免GS算法里反复迭代和选择初值的问题.

对于网络训练, 为了快速得到用于训练的数据集, 使用天线全息测量中较为常见的数值模拟仿真办法, 口径场相位用多项式来模拟真实的天线相位分布, 之后口径场相位结合高斯照明函数组成口径场, 利用傅里叶变换可以快速得到远场, 用于网络训练的口径场相位与远场幅值结对组成

数据集. 条件生成对抗网络的网络训练工作流程如图4所示. 条件对抗神经网络的相位恢复方法的网络训练包括数据集制造和数据训练两个部分.

## 3 条件生成对抗网络(CGAN)的构建

生成对抗网络具有卓越的非线性拟合能力, 在数据生成、数据处理等方面发挥作用. CGAN网络应用在相位恢复领域, 需要引入条件约束, 通过附加信息为模型增加条件  $y^*$ , 以指导数据生成过程.  $y^*$  可以是不同模态的数据, 本文将  $y^*$  定义为远场幅值, 该网络将  $y^*$  添加到输入层, 从而使原来的非监督对抗网络具有监督性. 参考U-Net (Convolutional Networks for Biomedical Image Segmentation) 架构, 设计一种基于编码器-解码器的CGAN框架<sup>[17-18]</sup>. 图5为本文CGAN网络

构造示意图, 其中生成器网络为 $G(z|y^*)$ ,  $z$ 为空白或随机初始值; 判别器网络为 $D(x^*|y^*)$ , 其中 $x^*$ 为

输入判别器网络的值,  $P$ 代表输入图像为真实图像的概率.

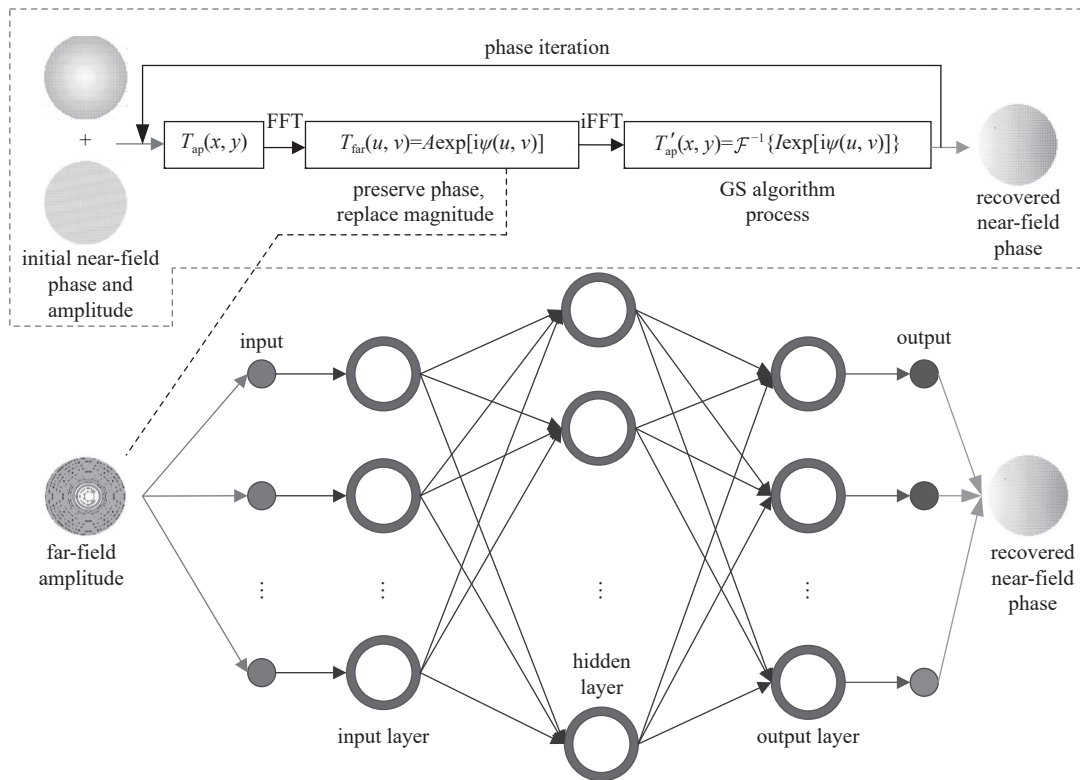


图 3 基于网络和GS算法的口径场相位恢复的示意图

Fig. 3 Schematic diagram of aperture field phase recovery based on network and GS algorithm

### 3.1 应用于相位恢复的生成器网络构建

生成器网络的6个下采样层用于减小特征图的尺寸并增加通道数, 5个上采样层和1个输出层用于图像重建. 每个下采样层创建一个2D卷积层, 设定输入和输出通道数, 使用 $3 \times 3$ 的卷积核, 其步长为2、填充为1. 随后应用LeakyReLU (Leaky Rectified Linear Unit)激活函数, 并将其直接写到输入张量中. 之后添加一个批量归一化层以归一化输出特征图. 定义一个前向传播接口, 以控制批量归一化. 上采样用于图像重建, 以恢复图像至原始尺寸. 构建一个转置卷积层进行上采样, 设定输入和输出通道数, 使用 $3 \times 3$ 的卷积核, 其步长为2, 填充为1. 同样应用LeakyReLU激活函数, 并将结果直接写入输入张量. 接着创建批量归一化层, 对输出特征图进行归一化处理. 然后构建一个前向传播接口, 定义了如何根据输入生成输出. 首先对

输入进行上采样, 再通过批量归一化层, 可选择在特定训练阶段使用Dropout以增强模型泛化能力. 最终输出层为转置卷积层, 将上采样后的特征图转换为最终输出, 将通道数转换为1个, 调整图像尺寸, 并通过tanh函数将输出归一化至 $[-1, 1]$ 范围.

### 3.2 应用于相位恢复的判别器网络构建

判别器网络包含两个下采样模块和一个输出层. 初始使用一个下采样模块, 输入为拼接的真实图像和生成图像. 第2个下采样模块进一步提取特征. 随后使用 $1 \times 1$ 卷积层调整特征图通道数, 接着应用批归一化和LeakyReLU激活函数. 通过调整 $1 \times 1$ 卷积核的数量, 将多通道的特征图转换为单通道的特征图, 并使用Sigmoid函数输出0到1之间的值. 在每一步上采样过程中, 通过调用相应的上采样层, 将当前层的输出与之前下采样层的特征图相结合. 这种特征融合有助于网络将之前提

取的细节整合到当前生成的图像中. 生成器网络和判别器在进行每次优化前, 需要清除优化器中的梯度, 防止梯度累积. 将生成器产生的相位及其对应标签输入判别器, 以获取判别器对生成相位的输出. 该输出反映了判别器对生成相位“真实性”的判断. 综合损失项, 计算生成器的总损失. 对总损失执行反向传播, 计算生成器中所有可训练参数的梯度, 并用于更新权重.

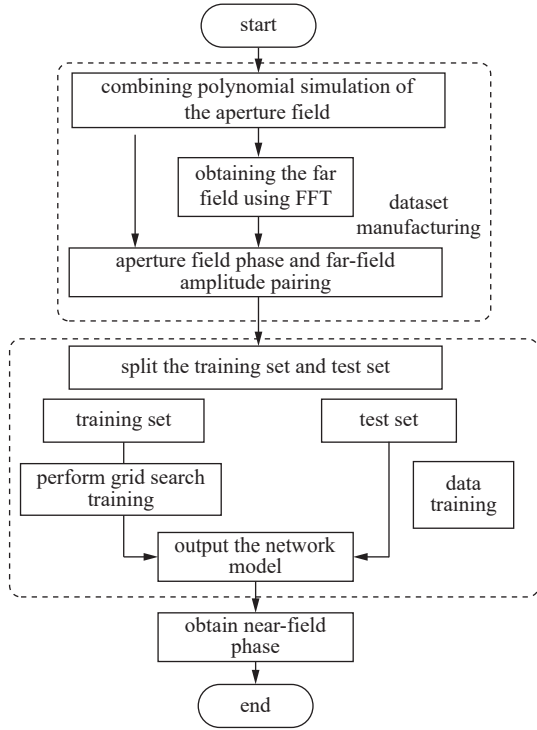


图 4 基于条件生成对抗网络的网络训练工作流程

Fig. 4 The network training workflow of CGAN

## 4 实验与分析

为了评估CGAN在相位恢复任务中的性能表现, 聚焦于其恢复的准确性、稳定性和计算效率. 采用结构相似性指数(Structural Similarity Index, SSIM)和均方根误差(Root Mean Square Error, RMSE)来评估相位恢复的效果. 较高的SSIM和较低的RMSE表示更好的恢复精度. 数据集制作包含口径场的构建和傅里叶变换得到的远场. 另外在测试集里的远场幅值添加噪声, 再输入到训练好的网络里恢复口径场相位, 将恢复结果与无噪声测

试集结果比较, 用来检验该网络对于噪声的抵抗能力. 另外需要将此网络恢复相位方法与单幅值输入迭代算法GS算法作为比较, 证明此网络恢复方法比GS算法更加精确且快速地恢复了口径场相位.

### 4.1 构建数据集

在网络训练过程中, 为了构建训练所需的数据集, 使用了相位恢复全息测量中采用的数值仿真方法. 天线表面变形会导致电磁波在传播路径上的微小变化, 进而引起光程差. 口径场相位分布与反射面光程差成正比, 其关系式为:

$$\phi = \frac{2\pi}{\lambda} \Delta L, \quad (6)$$

其中 $\Delta L$ 为光程差,  $\phi$ 为口径场相位,  $\lambda$ 为波长. 上式将天线表面的几何变形问题转化为光程差及相应相位的变化关系.

本文选取乌鲁木齐南山26 m卡塞格伦天线作为模型, 在工程实践中, 为了简化卡塞格伦天线的特性评估, 常运用等效抛物面理论对其进行近似分析, 26 m天线的主要参数如表1. 卡塞格伦反射面天线中的主反射面为圆抛物面, 反射面的表面误差分布可采用Zernike多项式进行描述:

$$\delta_S(r', \theta') = \sum [a_i Z_i(r', \theta')], \quad (7)$$

其含义为获得的光程误差分布, 其中 $r'$ 为表面S的径向坐标,  $\theta'$ 为角度坐标,  $a_i$ 为第 $i$ 项Zernike多项式系数, Zernike多项式在极坐标和直角坐标系表达如表2所示. Zernike多项式作为一组正交函数, 常用于波前分析和天线表面形状的描述. 运用Zernike多项式对光程误差分布进行模拟, 能够精确且高效地描绘该分布, 这些多项式与光学设计中常见的赛德尔像差(如离焦、像散、彗差等)系数相匹配, 便于描述反射面天线补偿由结构变形带来的影响. 结合Zernike多项式模拟实际天线的相位分布, 进而形成口径场相位. 将此口径场相位与高斯照明函数相结合, 构建出口径场模型. 通过傅里叶变换, 可以迅速计算出远场数据. 口径场相位与远场幅值对应配对构成用于网络训练的数据集. 针对反射面天线, 根据等效天线原理, 通常圆心处的口径场幅值最大, 向边缘逐渐均匀衰减. 一般而言, 口径场幅值分布用高斯照明函数来描述, 口径场相位则用三阶10项Zernike多项式来表示.

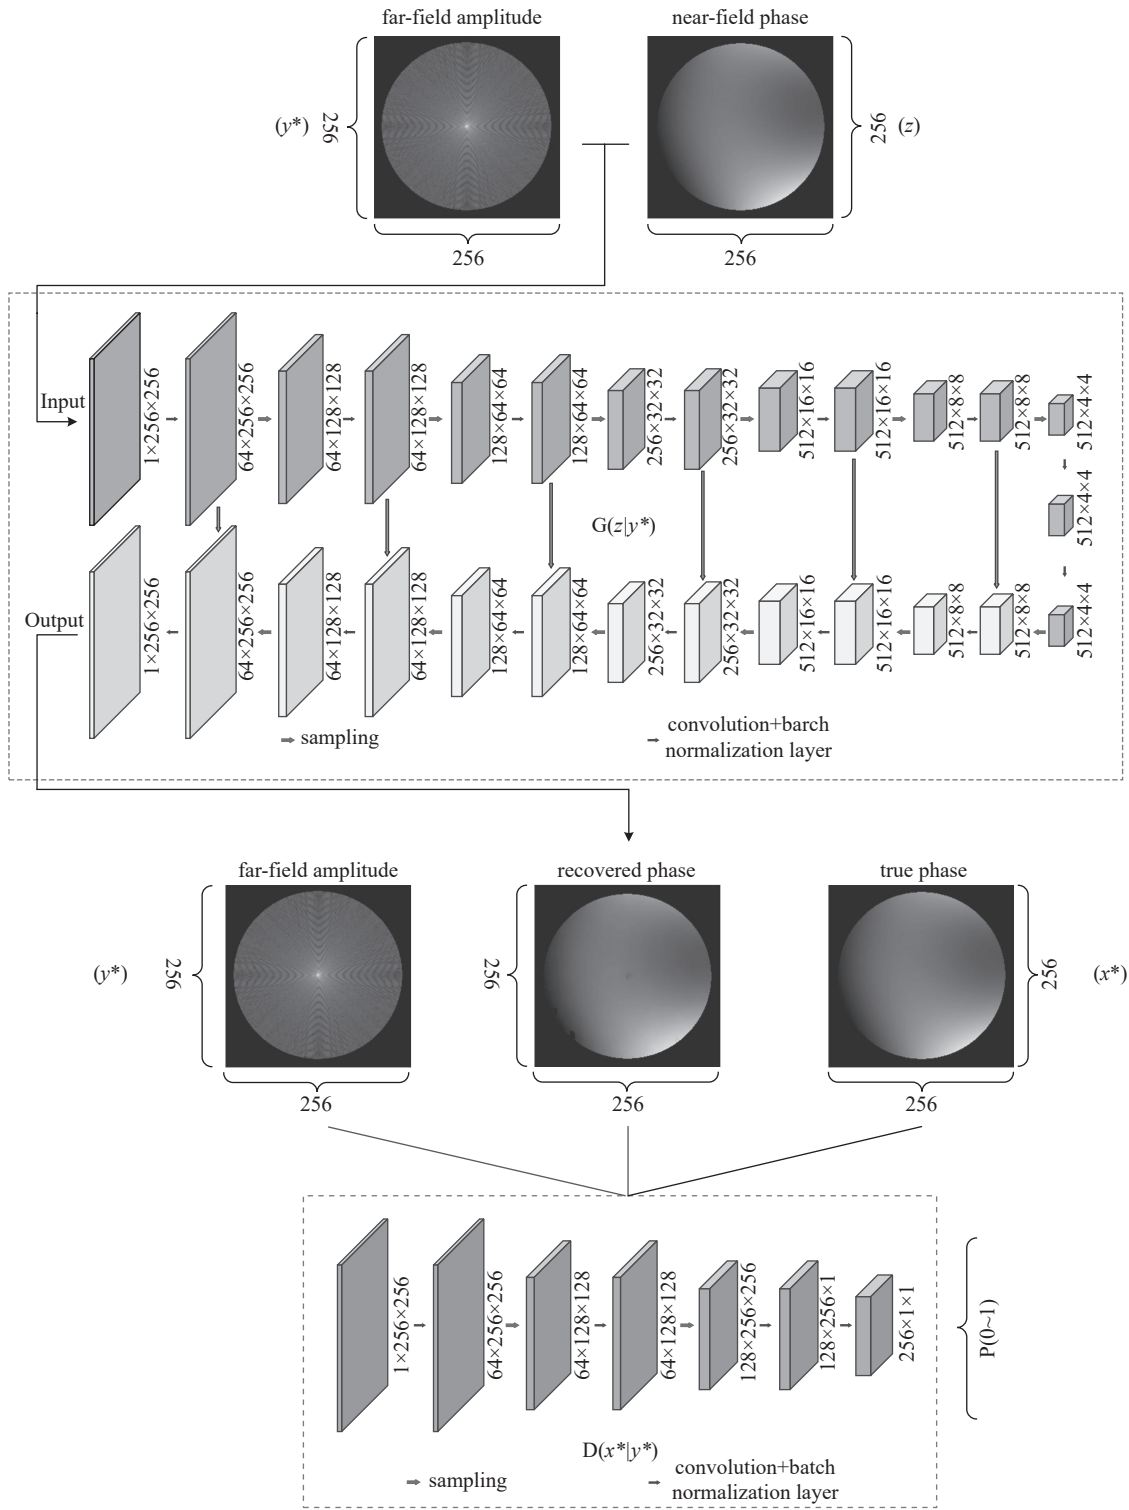


图 5 CGAN网络构造示意图

Fig. 5 Structure diagram of CGAN network

表 1 乌鲁木齐南山26 m天线主要参数

Table 1 The main parameters of the 26-meter antenna in Nanshan of Urumqi

Aperture diameter/m	Secondary face diameter/m	Edge taper/dB	Wavelength/cm	Focal length ratio
26	3	-16	1	0.3

表 2 Zernike多项式表达式

Table 2 Zernike polynomial expression

$i$	$Z_i(r', \theta')$	$Z_i(x, y)$	$i$	$Z_i(r', \theta')$	$Z_i(x, y)$
1	1	1	7	$r'^3 \sin 3\theta'$	$3x^2 - y^2$
2	$r' \sin \theta'$	$x$	8	$(3r'^3 - 2r') \sin \theta'$	$y [3(x^2 + y^2) - 2]$
3	$r' \cos \theta'$	$y$	9	$(3r'^3 - 2r') \cos \theta'$	$x [3(x^2 + y^2) - 2]$
4	$r'^2 \sin 2\theta'$	$2xy$	10	$r'^3 \cos 3\theta'$	$y (3x^2 - y^2)$
5	$2r'^2 - 1$	$2(x^2 + y^2) - 1$	11	$r'^4 \sin 4\theta'$	$4xy(x^2 - y^2)$
6	$r'^2 \cos 2\theta'$	$x^2 + y^2$	...	...	...

根据(6)式, 口径场相位可用三阶10项Zernike多项式表示为:

$$\varphi(x, y) = \frac{4\pi}{\lambda} \cdot [a_1 Z_1(x, y) + a_2 Z_2(x, y) + a_3 Z_3(x, y) + \dots + a_{10} Z_{10}(x, y)]. \quad (8)$$

口径场分布可表示为:

$$T_{\text{ap}}(x, y) = A \exp \{i\varphi(x, y)\}. \quad (9)$$

利用远场与口径场的傅里叶变换关系, 求得远场 $T_{\text{far}}$ 和远场幅值 $I = |T_{\text{far}}|^2$ . 这种方法基于傅里叶变换获取数据集, 避免了在远场中直接对数据进行复杂积分运算的高计算量, 能够迅速得到口径场的相位和远场幅值, 提升了计算效率.

数值模拟中, 设置10个-1到1的随机数共10000组, 保留小数点后两位, 利用(8)式, 将这10000组数组当作Zernike系数与相应的Zernike多项式组成新数组来得到口径场相位, 进而求得远场幅值. 由10000个构建的口径场相位与计算得来的远场幅值图像对组成数据集, 用于训练所提出的网络. 其中9500对作为训练数据集, 其余500组作为测试数据集. 远场强度图像和口径场相位图像以8位灰度图表示, 为了促进网络训练, 对数据集进行最小-最大归一化<sup>[19]</sup>. 上述数据准备过程均利用python在pycharm平台实现.

## 4.2 损失函数分析

我们在pytorch框架中实现了上文提出的CGAN网络. 将远场幅值和近场相位分布分别用作训练网络的输入和理论输出. 在训练过程中, 损失函数对相位恢复的性能有显著影响. 生成对抗网络对抗损失函数的定义为:

$$L_{\text{BCE}} = E_{x^* \sim P_{\text{data}}(x^*)} \ln [D(x^* | y^*)] + E_{z \sim P_{\text{data}}(z)} \ln \{1 - D[G(z | y^*)]\}, \quad (10)$$

式中 $E_{x^* \sim P_{\text{data}}(x^*)}$ 表示从真实数据分布 $P_{\text{data}}(x^*)$ 中采样数据 $x^*$ 的期望,  $E_{z \sim P_{\text{data}}(z)}$ 表示从输入噪声变量分布 $P_{\text{data}}(z)$ 中采样噪声的期望,  $\ln D(x^* | y^*)$ 表示判别器D在给定条件 $y^*$ 下, 对真实数据 $x^*$ 的对数概率,  $\ln [1 - D(G(z | y^*))]$ 表示判别器D在给定条件 $y^*$ 下, 对生成数据 $G(z | y^*)$ 对数概率的补概率.

均方误差(Mean Square Error, MSE)是回归损失函数中最常用的误差, 其定义如方程所示:

$$L_{\text{MSE}}(R, G) = \frac{1}{N} \sum_{i=1}^N (R_i - G_i)^2, \quad (11)$$

其中 $R$ 和 $G$ 分别表示恢复的相位图像和真实相位图像,  $N$ 是图像中像素的总数.

在相位恢复问题中, 由于MSE是一个全局标

准, 因此MSE损失函数在恢复部分相位细节时可能会遇到障碍. SSIM是一个范围从0到1的质量指标, 用于评估两张图像之间的结构相似性, 这在很大程度上弥补了MSE的弱点. 其定义为:

$$L_{\text{SSIM}}(R, G) = \frac{(2\mu_R\mu_G + c_1)(2\sigma_{RG} + c_2)}{(\mu_R^2\mu_G^2 + c_1)(\sigma_R^2\sigma_G^2 + c_2)}, \quad (12)$$

其中 $\mu_R$ 和 $\sigma_R$ 分别是恢复的相位图像的平均值和标准差,  $\mu_G$ 和 $\sigma_G$ 分别是真实相位图像的平均值和标准差,  $\sigma_{RG}$ 为协方差, 另外需要极小的常数参数 $c_1$ 和 $c_2$ 来确保数值稳定性.

将3个基本损失函数结合起来, 以追求更好的相位恢复性能, 所应用的损失函数的定义方程为:

$$l_1 = W_{\text{BCE}}L_{\text{BCE}} + W_{\text{SSIM}}(1 - L_{\text{SSIM}}) + W_{\text{MSE}}L_{\text{MSE}}, \quad (13)$$

其中,  $W_{\text{BCE}}$ 、 $W_{\text{SSIM}}$ 、 $W_{\text{MSE}}$ 代表了相应损失函数的权重, 为了平衡损失比分别设置为2、1和16. 使用Adam优化器优化损失函数, 通过观察验证损失的变化趋势来降低学习率, 直到训练数据集和测试数据集的损失都稳定收敛则训练过程停止.

### 4.3 网络训练结果分析

网络训练是在配备RTX 3080x2 (20 GB) GPU与12 vCPU Intel (R) Xeon (R) Platinum 8352V CPU的云电脑上完成的. 在本研究中, 直到训练数据集和测试数据集的损失都稳定收敛, 训练过程停止, 总训练时间为12 h. 为了描述网络学习, CGAN网络在学习过程中的训练损失和验证损失曲线与次数的关系如图6 (a)所示. 损失曲线在大约60个epoch时收敛. 验证损失曲线数值与训练损失曲线接近, 说明CGAN网络与验证数据集拟合良好. 对于归一化的测试数据集, 图6 (b)箱线图所示其对应的相位恢复RMSE范围集中在0.0054, SSIM集中在0.9981. 远场强度图像常受到各种噪声干扰. 向上述训练过程里作为测试集的500张强度图像中添加了代表性的泊松噪声, 并在不同信噪比(SNR = 25~26 dB)的噪声水平下, 对网络模型进行了测试. 相位恢复的平均SSIM和RMSE如图6 (c)所示. 其SSIM集中在0.9940, RMSE集中在0.0077, 仍处于较高的水平. 表明CGAN在处理泊

松噪声时, 仍能实现较好的相位恢复效果.

现在设计一批次测试集, 检验理想情况(无噪声)下的网络恢复口径场相位效果, 为了构建口径场相位, 设置4组10个-1到1的随机数作为Zernike系数, 如表3所示. 测试集制作方法与上述构建数据集方法一样, 得到了4组远场幅值如图7 (a), 口径场相位如图7 (c).

将这4组远场幅值输入到网络里, 网络输出的口径场相位如图7 (d). 通过CGAN的训练过程, 得到测试数据集的相位恢复结果, 与真实相位相比, 网络恢复了口径场相位的全局轮廓和大多数特征. 另外使用表3的Zernike系数建立一批次测试集, 并在远场幅值里添加泊松噪声, 在泊松噪声影响下, 重建的远场强度如图7 (b)所示, 远场强度图像中心受到泊松噪声的严重破坏. 真实相位与通过CGAN恢复的相位分别如图7 (c)和图7 (e)所示, 可以看出用添加了泊松噪声的远场幅值作为输入时, 网络仍然恢复了口径场相位的全局轮廓和大多数特征.

为了研究噪声对CGAN网络相位恢复的影响机制, 在上述4组测试集里添加SNR在10~60 dB范围的泊松噪声, 图8展示了天线远场信噪比与口径场恢复相位RMSE之间的关系. 从图中可以看出, 天线远场的信噪比越高, 测量误差的RMSE值越小, 表明通过CGAN恢复的天线口径场相位与真实相位的接近程度越高. 由实验数据可知当信噪比低于30 dB时, CGAN恢复的口径场相位RMSE随着信噪比的增加而迅速降低; 进入30~40 dB过渡区间后, 误差衰减曲线趋于平缓, 表明这一范围内, 信噪比对恢复精度的提升效果有限; 当信噪比突破40 dB, RMSE的变化幅度几乎微乎其微, 并趋于稳定, 说明在高信噪比条件下, 进一步提高信噪比对恢复精度的改善作用几乎可以忽略.

增加的噪声可以被视为对网络的一种干扰. 深度学习架构大量的参数在训练过程中通过优化进行调整以最小化预测误差. 网络的深度和复杂性使得它能够捕捉到输入数据中的高级特征和模式. 这些大量的参数和非线性的网络层共同作用, 使得网络具备了一定的容错能力. 网络的这种特性使其能够在面对噪声干扰时, 仍然可以保持较

高的性能和准确性,使得模型具备较强的鲁棒性,结果.能在一定程度上抵御噪声干扰,保持稳定的输出

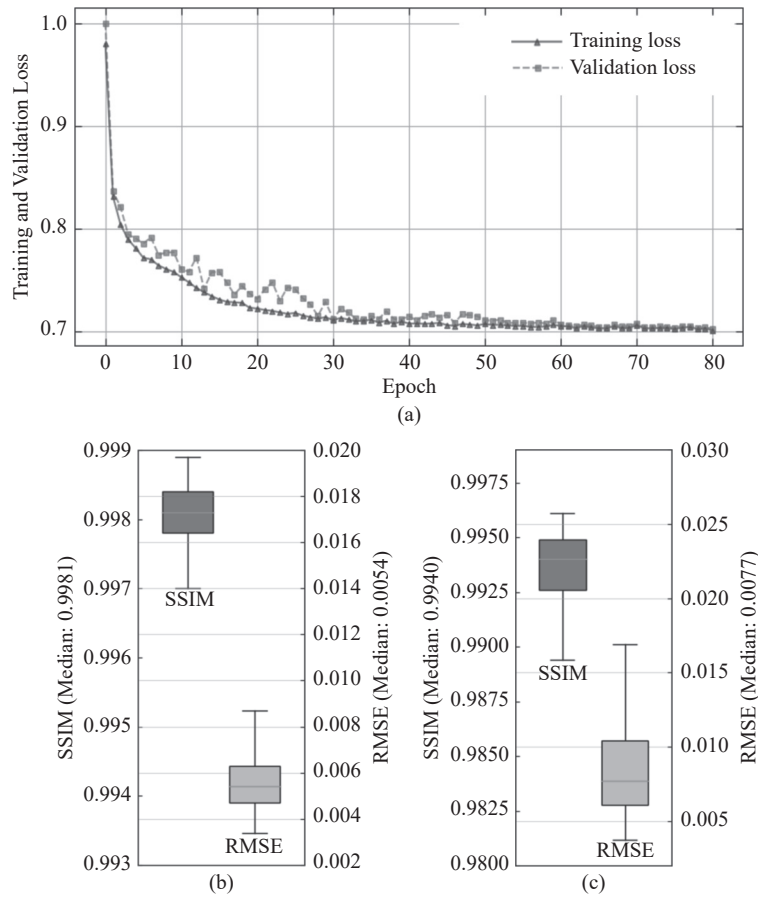


图 6 CGAN的训练结果

Fig. 6 Training results of CGAN

表 3 测试集需要的Zernike系数

Table 3 The Zernike coefficients required for test sets

Number of groups	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$	$a_7$	$a_8$	$a_9$	$a_{10}$
I	0.01	-0.10	-0.17	-0.25	-0.35	-0.16	0.16	-0.06	0.13	-0.22
II	-0.09	-0.14	0.00	-0.13	-0.06	0.01	-0.02	-0.08	-0.03	-0.17
III	0.00	-0.14	-0.31	-0.23	0.01	-0.12	0.00	-0.18	-0.20	-0.01
IV	-0.10	0.010	-0.12	-0.28	-0.18	0.00	-0.08	-0.04	0.00	-0.30

#### 4.4 CGAN恢复相位法与GS算法的对比

CGAN恢复相位法与GS算法两者都仅使用单个远场强度图像.为了对比两种方法恢复口径场

相位的效果,设置4组10个-1到1的随机数作为Zernike系数,过程如数据集制作一样,其需要的Zernike系数如表4所示.

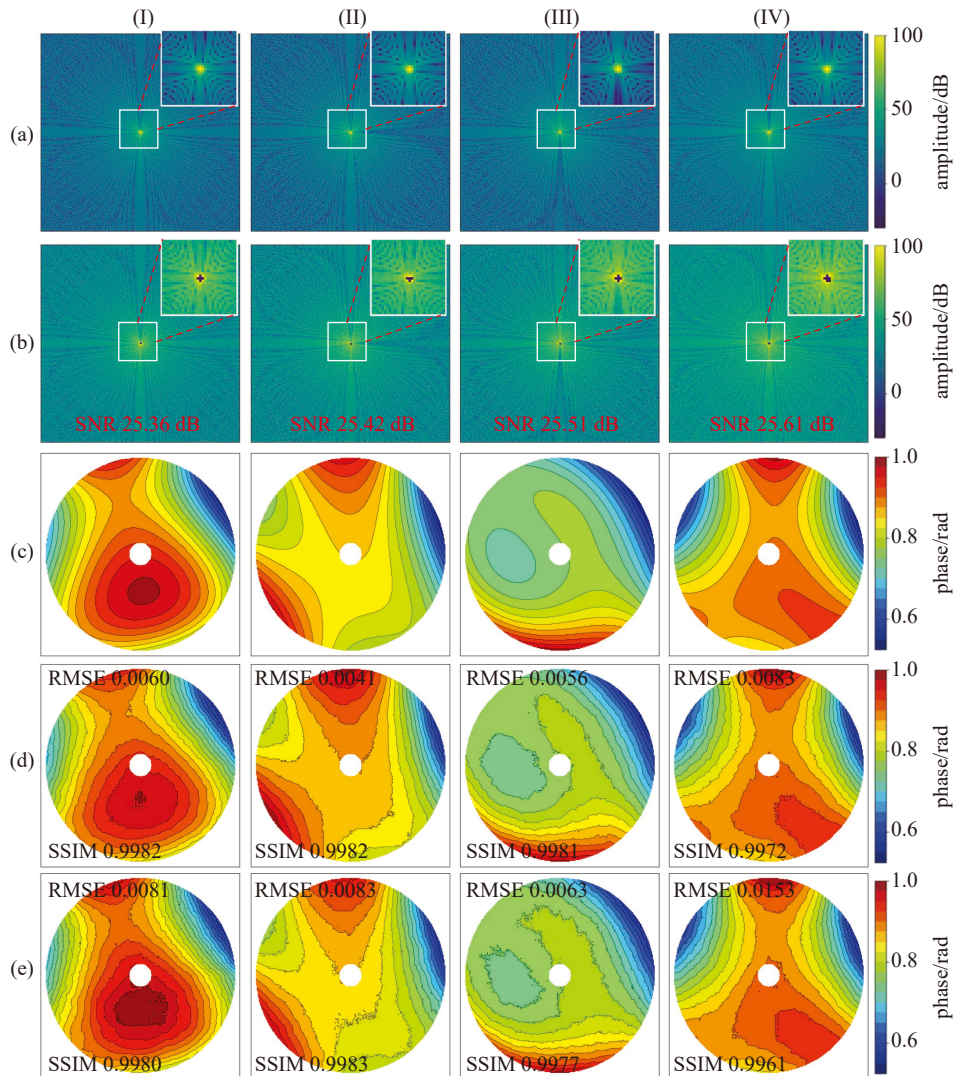


图 7 测试集网络恢复效果

Fig. 7 Network recovery performance on test sets

使用CGAN与GS算法分别输入单个远场强度图像进行相位恢复, 原始相位图像、CGAN和GS恢复的相位图像分别如图9 (a)、(b)和(c)所示. 两者都仅使用单幅远场幅值, GS算法无法精确恢复口径场相位信息, 而CGAN能精确恢复口径场相位. 在GS恢复的相位图像中(图9 (c)), (III)的相位恢复精度最高. 为了进一步说明两种相位恢复算法的性能, 图10 (a)和(b)分别显示了(III)中的水平和垂直剖面曲线. 从剖面曲线可以清晰看出

CGAN网络的恢复相位已经很接近真实相位, 而GS恢复的剖面曲线与真实相位的剖面曲线有较大偏差. 上述计算都是在配备Intel Core i5-11400 H的CPU和16 GB RAM的笔记本电脑上运行的. 如图11所示, GS算法一般需要经多次迭代后远场幅值的RMSE才能收敛. 对于上述4组例子, GS算法收敛平均用时12.1608 s. CGAN网络从读取模型到解码完平均用时0.0508 s, 在运行时间上CGAN网络恢复具有明显的优势.

该实验结果表明, 所提出的CGAN已经学习了输入远场强度图像和输出口径场相位图像之间的映射. 通过训练数据集学习后另外建立测试集, 仅使用其中单幅远场强度图像作为网络输入, 通过CGAN获得定量相位恢复, 通过观察恢复相位的轮廓及RMSE和SSIM, CGAN呈现出优异的相位恢复性能, 证明了该模型的准确性和可行性. 此外使用一批次测试集, 比较CGAN和GS算法的恢复相位性能, 结果表明GS算法无法精确恢复数值模拟中的相位, 且GS算法需要经历较多的迭代才能收敛, 这使得GS算法变得耗时, 而CGAN能迅速完成相位恢复.

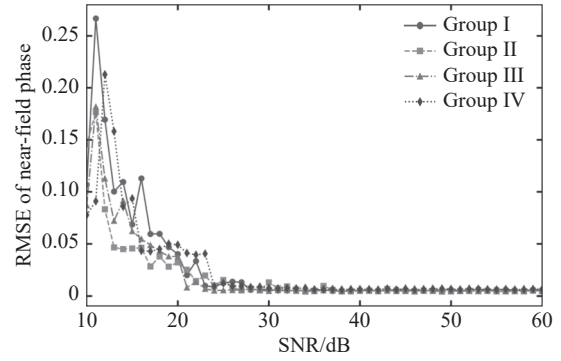


图 8 远场信噪比对恢复相位的RMSE的影响

Fig. 8 The impact of far-field signal-to-noise ratio on the RMSE of recovered phase

表 4 仿真口径场相位需要的Zernike系数

Table 4 The Zernike coefficients required for simulating near-field phase

Number of groups	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$	$a_7$	$a_8$	$a_9$	$a_{10}$
I	-0.15	-0.22	-0.10	-0.09	-0.14	-0.07	-0.09	0.02	-0.11	-0.16
II	-0.01	0.12	-0.22	-0.33	-0.08	-0.05	-0.20	-0.28	-0.11	-0.17
III	-0.27	-0.23	-0.07	0.18	-0.07	0.02	-0.15	-0.08	-0.08	-0.08
IV	-0.25	0.04	-0.18	-0.10	-0.16	-0.08	-0.30	-0.04	-0.13	-0.20

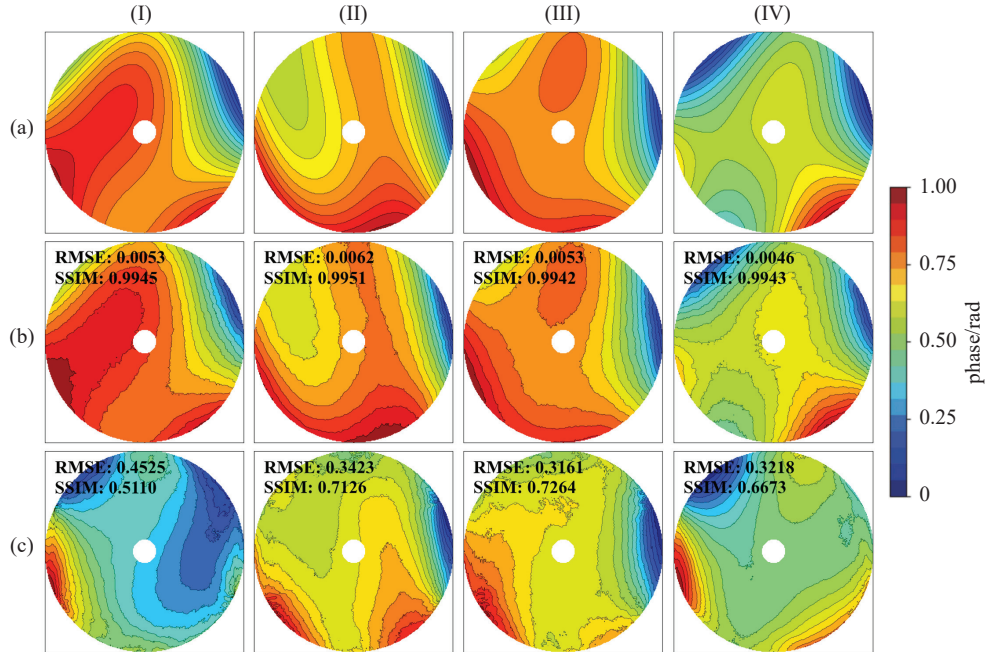


图 9 GS算法与CGAN网络模型恢复近场相位对比图

Fig. 9 Comparison chart of near-field phase recovery between the GS algorithm and the CGAN model

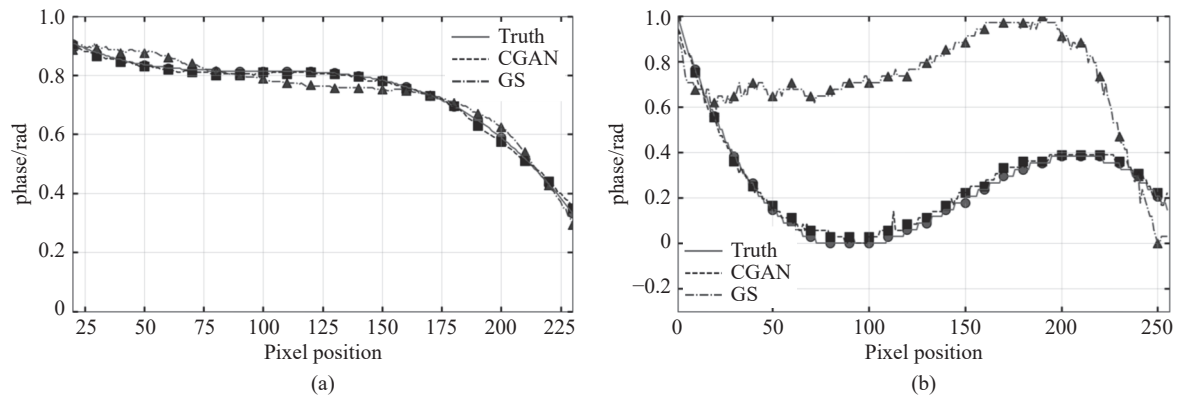


图 10 GS算法与CGAN网络模型恢复口径场相位截面对比图

Fig. 10 Cross-sectional comparison chart of near-field phase recovery between the GS algorithm and the CGAN model

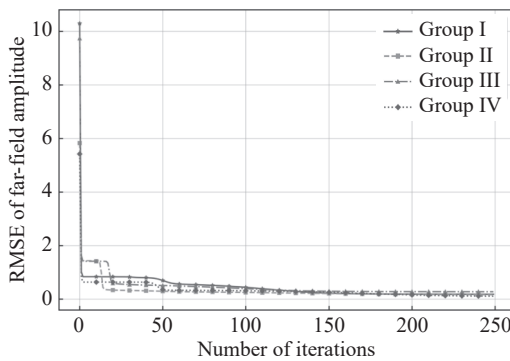


图 11 GS算法远场幅值迭代RMSE

Fig. 11 RMSE of far-field amplitude using the GS algorithm

## 5 结论

本文提出的算法模型成功实现了对口径场相位的精确恢复. 该方法沿袭了相位恢复全息法的优势, 即无需依赖参考信号, 仅需输入远场幅度即可获取相位信息. 该网络仅需单张远场强度图像, 便能展现出卓越的相位重建性能. 在数值模拟实验中, 该方法不仅实现了定量和定性的相位恢复, 且相较于单输入相位恢复的GS算法, 展现出更高的精度和更快的计算速度, 同时免去了对口径场幅值及初值选择等先验知识的依赖. 用于口径场相位恢复的CGAN网络对泊松噪声表现出显著的

鲁棒性, 能够在相位恢复过程中有效发挥降噪作用. 该方法前景广泛, 可为超大口径天线面形的快速校准提供支持.

## 参考文献

- [1] Rahmat-Samii Y. ITAP, 1985, 33: 1194
- [2] 李广云. 测绘通报, 1998, 10: 4
- [3] 白杨. 电子设计工程, 2018, 26: 84
- [4] Gerchberg R W. Optik, 1972, 35: 237
- [5] Morris D. ITAP, 1985, 33: 749
- [6] Fienup J R. ApOpt, 1982, 15: 2758
- [7] Dong B. JOSAA, 1997, 14: 2709
- [8] Nikolic B. A&A, 2007, 2: 679
- [9] Nishibori T. E&C, 1996, 79: 104
- [10] 韩涛, 吕静. 天文学报, 1994, 35: 209
- [11] Misell D L. JPhD, 1973, 6: 2200
- [12] Tong Z, Ye Q, Xiao D, et al. OptLE, 2021, 143: 106619
- [13] Zou Q. IGRSL, 2022, 19: 1
- [14] Isola P. Image-to-Image Translation with Conditional Adversarial Networks. Conference on Computer Vision and Pattern Recognition, Hawaii, July 22-25, 2017
- [15] Tang B. IEEEA, 2018, 6: 15713
- [16] Zou C. IComM, 2024, 62: 58
- [17] Ronneberger O, Fischer P, Brox T, et al. LNCS. Switzerland: Springer International Publishing, 2015, 9351: 234
- [18] 官成功, 高勇. 通信技术, 2021, 3: 568
- [19] Goodfellow I, Mirza M, Courville A, et al. CACM, 2020, 63: 139

# Adversarial Neural Network-Based Phase Retrieval from Single Far-Field Data for Reflector Antennas

ZHANG Yang<sup>1</sup>    XIANG Bin-bin<sup>1</sup>    WANG Wei<sup>2</sup>    LIN Shang-min<sup>3</sup>    CUI Han-wei<sup>1</sup>  
ZHENG Tian-xiang<sup>1</sup>    ZHOU Jian-ping<sup>1</sup>    HE Da-lin<sup>4</sup>

(1 School of Mechanical Engineering, Xinjiang University, Urumqi 830011)

(2 School of Mechatronic Engineering, Xidian University, Xi'an 710119)

(3 Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119)

(4 Xinjiang Astronomical Observatory, Chinese Academy of Sciences, Urumqi 830011)

**ABSTRACT** Microwave holographic measurement technology is widely utilized in the surface measurement of telescopes, among which the phase recovery method is extensively applied in the surface calibration of radio telescopes due to its elimination of the need for additional specialized equipment. This method typically employs inversion algorithms to iteratively obtain an approximate near-field phase from far-field intensity data of the antenna. To enhance computational efficiency, this paper adopts deep learning techniques and designs a model based on the Conditional Generative Adversarial Network (CGAN) approach to address the issue of near-field phase recovery for reflector antennas under single-input far-field amplitude conditions. The phase recovery method proposed by this model dispenses with the traditional reliance on prior knowledge and the time-consuming iterative process. The original CGAN loss function has been augmented by incorporating Mean Squared Error (MSE) and Structural Similarity Index (SSIM) loss functions to optimize network training and improve the precision of phase recovery. Validation has shown that the CGAN network is robust against Poisson noise and can serve as a denoising tool in the phase recovery process. The CGAN framework not only enhances the precision of phase recovery and reduces computational complexity but also contributes to solving phase recovery issues in Fourier imaging systems. Moreover, this method can be extended to phase error measurement in other fields.

**Key words** techniques: phase retrieval, methods: numerical, methods: data analysis