

基于深度展开网络的微波计算成像技术

史洪印^{1,2}, 彭毓晗^{1,2}, 温裕广^{3*}, 黎芳^{1,2}, 刘慧^{1,2}

(1. 北京建筑大学电气与信息工程学院, 北京 100044; 2. 建筑大数据智能处理方法研究北京市重点实验室, 北京 100044;
3. 航天新气象科技有限公司, 北京 100048)

摘要: 信息超材料是一种人工结构阵列, 其能够通过设计单元参数的排列方式定制等效材料和媒质属性, 实现对电磁场和电磁波的灵活调控, 带来全新的物理现象。基于信息超材料孔径的微波计算成像 (Microwave Computational Imaging based Information Metamaterial Aperture, IMA-MCI) 技术可以不依赖于雷达平台与目标之间的相对运动, 在波束内实现目标的高分辨率成像。在微波成像过程, 由于信息超材料天线的制作工艺限制, 可能会导致相位误差的产生, IMA-MCI 在有相位误差的情况下, 对目标场景的重构能力不足。针对该问题, 本文构建了基于反射式信息超材料天线的微波计算成像模型, 提出一种结合深度展开网络和相位恢复算法的成像技术。该算法在相位恢复算法的基础上引入了动态超网络为原有网络生成阻尼因子, 能够根据输入场景不同进行调整, 在线生成阻尼因子, 在系统的参数发生变化时仍然具有较好的性能。实验结果显示, 该方法具有较好的成像性能和鲁棒性。

关键词: 微波计算成像; 信息超材料; 相位恢复; 深度学习; 超网络

基金项目: 国家自然科学基金 (No.62071414); 北京市教育委员会科技计划 (No.KZ202210016021)

中图分类号: TN958

文献标识码: A

文章编号: 0372-2112(2024)12-4048-11

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

DOI: 10.12263/DZXB.20230920

Microwave Computational Imaging Technology Based on Deep Unfolding Network

SHI Hong-yin^{1,2}, PENG Yu-han^{1,2}, WEN Yu-guang^{3*}, LI Fang^{1,2}, LIU Hui^{1,2}

(1. School of Electrical and Information Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;
2. Beijing Key Laboratory of Intelligent Processing for Building Big Data, Beijing 100044, China;
3. Aerospace Newsky Technology Co. Ltd., Beijing 100048, China)

Abstract: Information metamaterial is an artificial structure that can customize its equivalent material and media properties by designing unit parameters and arrangement, and realize free control of electromagnetic fields and electromagnetic waves, thereby bringing new physical phenomena. Information Metamaterial Aperture-based Microwave Computational Imaging (IMA-MCI) technology can achieve high-resolution imaging of targets within the beam without relying on the relative motion between the radar platform and the target. In microwave imaging, due to the limitations of the fabrication process of information metamaterial antennas, phase errors may be caused, and it is still challenging for IMA-MCI to reconstruct the target scene under the condition of phase error. To solve this problem, a microwave computational imaging model based on reflective information metamaterial antenna is constructed, and an imaging technology based on the combination of deep unfolding network and phase retrieval algorithm is proposed. Based on the phase retrieval algorithm, the algorithm introduces a dynamic super network to generate damping factors for the original network, and introduces a recurrent neural network, which can generate damping factors online according to the model, and still has good performance when the parameters of the system change. Experimental results show that the proposed method has good imaging performance and robustness.

Key words: microwave computational imaging; information metamaterials; phase retrieval; deep learning; hypernetwork

Foundation Item(s): National Natural Science Foundation of China (No.62071414); Research and Development Program of Beijing Municipal Education Commission (No.KZ202210016021)

1 引言

微波成像相较于光学成像在复杂电磁环境中具有显著优势. 由于传统前视成像信噪比较低, 并且容易受各种干扰源的影响, 这些因素会导致成像质量下降. 因此, 基于信息超材料孔径的微波计算成像 (Information Metamaterial Aperture-based Microwave Computational Imaging, IMA-MCI)^[1] 为实现前视/凝视高分辨率成像问题提供了新思路, 在无损检测、安全预警、医学检测、导弹精确制导等方面有着广泛的应用前景. 在 IMA-MCI 系统中, 对相位信息进行测量时花费的成本较高^[2], 回波中相位信息可能会存在一定程度的偏差, 包括由信息超材料天线存在的误差引起的相位误差^[3]. 这些误差会造成系统成像性能降低, 从而使成像质量变得更差.

在微波计算成像系统中, 目标重构算法扮演着关键角色, 它对系统的性能有着显著影响. 因此, 探索性能更好的计算成像算法显得尤为重要. IMA-MCI 系统在重建目标时, 需要利用回波的幅度和相位信息. 然而, 在实际测量中相位信息可能存在误差, 因此, 可以采用相位恢复 (Phase Retrieval, PR) 理论与算法来重建目标.

相位恢复算法在很多领域都有着广泛应用, 如全息摄影技术、X 射线衍射摄影术、光学加密及波前相位检测等^[4]. 1982 年 Fienup 等人^[5] 提出的混合输入、输出算法 (Hybrid Input-Output, HIO), 是基于迭代投影的算法. 但这一算法鲁棒性不足. 2015 年, Candès 等人^[6] 提出了维尔廷格流 (Writing Flow, WF) 算法, 该算法为近几年非凸算法的研究提供研究基础, 但 WF 算法需要的样本数量太多. 2016 年, Zhang 等人^[7] 为改进 WF 算法, 提出重塑维尔廷格流算法 (Reshaped Wirtinger Flow, RWF), 这一算法的运算成本比 WF 低, 且计算速度也高于 WF 算法. 随后, Wang 等人^[8] 提出截断幅度流算法 (Truncated Amplitude Flow, TAF), 在 RWF 算法的基础上改善了异常梯度分量对结果的影响. 2017, He 等人^[9] 提出了广义期望一致算法 (Generalized Expectation Consistent, GEC), GEC 算法可以应用于各种类型的缺失数据模式. 它提供了灵活性、一致性以及处理各种类型的缺失数据模式和变量类型的能力.

随着深度展开网络的发展, 使用深度展开网络代替传统的迭代优化模式可以显著提高收敛性能^[10-12]. 当前深度学习的发展方向之一是物理模型驱动, 即在深度学习中引入特征规则先验, 以替代纯粹的数据驱动学习方法^[13-15]. 2020 年, Wang 等人^[16] 提出名为 PhymNet 的物理增强型神经网络架构, 将传统深度神经网络与描述图像生成过程的物理模型结合. 这种方法通过神经网络和物理模型之间的相互作用自动优化网

络, 就能得到待测对象的相位信息, 不需要大量的训练数据. 同年, Naimipour 等人^[17] 基于物理模型驱动数据深度展开技术, 提出一种名为 UPR 混合框架的网络. 该框架在处理非凸相位恢复问题上展现出巨大的潜力.

由于传统的相位恢复算法收敛性较差, 而基于深度展开的相位恢复算法由于将传统的物理模型与深度神经网络相结合, 泛化能力较弱, 适用场景有限. 基于上述问题, 本文提出了基于动态超网络的 GEC 成像算法, 该算法可在不同的应用场景中灵活调整, 来保证该算法的性能更加稳定^[18].

2 系统相位误差分析

目前, IMA-MCI 系统在实际应用中还面临着诸多不可回避的误差: 一是受加工工艺所限, 各超构表面单元之间的相位调制存在一定程度的偏差; 二是如果从成像网格面到发射天线的距离测量精度不够, 将会产生很大的误差. 下面通过仿真实验来分析系统的相位误差.

考虑 1 个方形超表面, 它包含 $N \times N$ 个维数为 D 的等大小晶格, 如图 1 所示.




图 1 $N \times N$ 等大小的维数为 D 的格子

将相位偏移的单元引起的相位误差设为 φ_e , 每个单元的散射相位为 $\varphi(m, n)$, 则具有移相误差的辐射场可以表示为^[19]

$$f(\theta, \varphi) = f_e(\theta, \varphi) \sum_{m=1}^N \sum_{n=1}^N \exp \left\{ j \left[\varphi(m, n) + \varphi_e \right] + kD \sin \theta \left(m - \frac{1}{2} \right) \cos \varphi + (n - 0.5) \sin \varphi \right\} \quad (1)$$

式中, θ 和 φ 分别为任意方向的仰角和方位角; $f_e(\theta, \varphi)$ 是晶格的模式函数, 表示晶格对不同仰角和方位角的响应. 仰角 θ 代表垂直方向, 方位角 φ 代表水平方向. 模式函数 $f_e(\theta, \varphi)$ 用于描述晶格在不同入射角的响应.

因为可编码超材料中存在的温度、位置等因素会导致相位误差, 所以令 $\varphi_e \in [-6^\circ, 6^\circ]$, 模拟信息超材料

因制作工艺引起的相位误差,实验结果如图2所示,可以看出相位调制误差对幅度和相位都产生了显著影响.

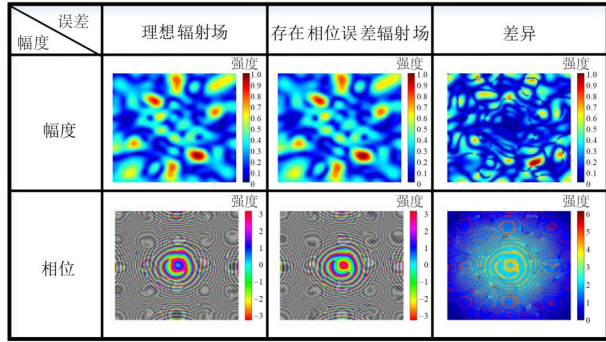


图2 相位误差对辐射场幅度和相位的影响

3 基于信息超材料的MCI系统模型

传统的孔径编码成像系统结构^[20]如图3所示.该系统主要由控制模块、发射装置、信息超材料、接收设备、信号处理装置组成.

假设信息超表面的编码元素为 Q 个,成像平面网格为 L 个,每个成像网格的反射中心位于其中心位置,馈源发射1个线性调频信号,则接收机接收到的第 l 个网格散射的信号为

$$\begin{bmatrix} S_r(t_1) \\ S_r(t_2) \\ \vdots \\ S_r(t_M) \end{bmatrix} = \begin{bmatrix} S(t_1, 1) & S(t_1, 2) & \cdots & S(t_1, L) \\ S(t_2, 1) & S(t_2, 2) & \cdots & S(t_2, L) \\ \vdots & \vdots & \ddots & \vdots \\ S(t_M, 1) & S(t_M, 2) & \cdots & S(t_M, L) \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_L \end{bmatrix} + \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_M \end{bmatrix} \quad (4)$$

将其写为矩阵形式为

$$\mathbf{S}_r = \mathbf{S} \cdot \mathbf{x} + \boldsymbol{\omega} \quad (5)$$

其中, $\mathbf{S}_r \in \mathbb{C}^{M \times 1}$ 为接收信号矢量, $\mathbf{S} \in \mathbb{C}^{M \times L}$ 为参考矩阵, $\mathbf{x} \in \mathbb{C}^{L \times 1}$ 为成像网格散射系数矢量, $\boldsymbol{\omega}$ 是加性噪声.在相位信息缺失时,成像方程为

$$\mathbf{y} = |\mathbf{S} \cdot \mathbf{x} + \boldsymbol{\omega}|^2 \quad (6)$$

由式(6)可以看出,这个方程是非线性的,而求解这个方程就是1个非凸问题.经典的正交匹配追踪算法(Orthogonal Matching Pursuit, OMP)、全变分正则化算法(Total Variation Augmented Lagrangian alternating direction algorithm, TVAL3)和反向传播算法(Back-propagation Algorithm, BP)等算法已无法满足上述问题的要求,此时就需要相位重构算法来解决上述问题.

4 基于深度展开的GEC算法

深度展开网络源于传统的迭代模式,具备原有的物理模型特征,其核心在于将迭代过程转化为神经网




图3 基于反射式信息超材料的成像模型^[19]

$$S_r(t_m, l) = x_l \sum_{q=1}^Q A \exp \left[j2\pi(f_0(t_m - \frac{d}{c}) + \frac{K}{2}(t_m - \frac{d}{c})^2) \exp(j\phi_{t_m, q}) \right] \quad (2)$$

其中, A 表示信号的幅度, f_0 表示载波频率, K 表示调频率, c 表示光速, d 表示信号传播距离, $\phi_{t_m, q}$ 是在 t_m 时刻编码孔径第 q 个元素的调制相位因子.

实际情况下 t_m 时刻的回波可以表示为

$$S_r(t_m) = \sum_{l=1}^L x_l S(t_m, l) \quad (3)$$

其中, x_l 为第 l 个网格单元的散射系数.

将整个测量过程中的测量次数设置为 M ,加入 t_m 时刻的加性噪声 ω_m ,则可将成像方程写为

络,从而用神经网络替代迭代算法,而不仅仅依赖数据,这种方法被称为模型驱动网络^[21].该网络与深度展开结合既保证了相位恢复算法的有效性,又降低了复杂性^[22].但依然受到固定迭代次数的约束.因此在深度展开网络中引入超网络,从而提升其在不同应用场景下的鲁棒性.

4.1 贝叶斯估计器

假设 \mathbf{z} 的概率密度函数为 $p(\mathbf{z})$,对后验分布 $p(\mathbf{z}|\mathbf{y})$ 的期望做近似,后验分布可以表示为

$$p(\mathbf{z}|\mathbf{y}) = \frac{f(\mathbf{y}|\mathbf{z})p(\mathbf{z})}{p(\mathbf{y})} \quad (7)$$

其中, $f(\mathbf{y}|\mathbf{z})$ 表示似然函数, $p(\mathbf{y}) = \int f(\mathbf{y}|\mathbf{z})p(\mathbf{z})d\mathbf{z}$ 表示边际分布.

由于通常使用后验分布期望值来进行参数估计.因此,后验分布的均值为 \mathbf{z} 的贝叶斯估计如下:

$$\hat{\boldsymbol{\mu}}_{\mathbf{z}} = \int \mathbf{z}p(\mathbf{z}|\mathbf{y})d\mathbf{z} \quad (8)$$

z 的后验方差为

$$\hat{v} = \int |z|^2 p(z|y) dz - |\hat{\mu}_z|^2 \quad (9)$$

这就是最小均方误差 (Mean-Square Error, MSE).

4.2 GEC 算法

目前已经有许多种解决贝叶斯估计的方法,其中 GEC 使用了期望一致或矩匹配来近似 $p(z|y)$.

GEC 算法可以被看作模块 A、B、C 不断迭代的过程,如图 4 所示. 对于 1 个成像模型 $y = |Sx + \omega|^2$. 首先假设存在 1 个向量用 $z = Sx$ 表示,则 x 到 y 的过程可以表示为 $x \rightarrow z \rightarrow y$. 由 y 到 x 的过程则遵循 $y \rightarrow z \rightarrow x$, 下面详细说明各模块的工作流程^[18].

幅值 y 和 z 的先验信息为模块 A 的输入, z 的估计值




图4 GEC 迭代流程

为模块 A 的输出. 因为 z 是通过幅度信息恢复出来的, 因此模块 A 可视为 1 个相位重建器.

模块 B 是通过线性变化 $z = Sx$ 来估计 z 或 x 的值, z 的先验信息或 x 的先验信息是模块 B 的输入, z 或 x 的后验估计为模块 B 的输出. 根据其处理方向决定其输出为 z 或 x 的后验估计, 用 Bx 和 Bz 分别表示. 模块 B 的 2 个方向都是根据同 1 个线性变换, 所以可视为 1 个线性重构器.

模块 Bx 的输出为模块 C 的输入, x 的估计值为模块 C 的输出. 因为模块 C 是从实际的先验分布中估计 x , 所以可视为 1 个去噪器.

这 3 个模块可以被看作是以不同的先验信息来重建 z 或 x , 并且循环的来重复执行这些模块, 直至其收敛为止.

4.3 GEC-Net 算法

在 GEC 的基础上, 将 GEC 中原本的迭代流程拓展为 1 个 T 层的网络, 每次迭代对应 1 个网络层, 设置层数 T 与迭代次数相同, 构建 1 个神经网络^[18].

在模块 A 和模块 C 之后引入 2 个阻尼因子. 来增加展开网络的收敛性. 阻尼因子 β 可通过神经网络.

深度展开网络各层由 4 个模块构成, 如图 5 所示. 下面对第 t 层的步骤进行说明.

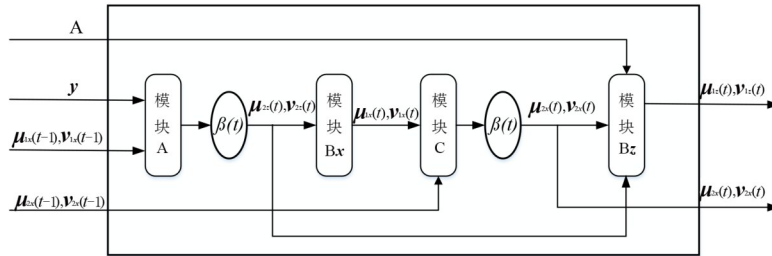


图5 第 t 层的结构

幅值 y 和 z 的先验信息为模块 A 的输入, z 的无偏估计为模块 A 的输出, 令 z 遵循高斯分布, 记作 $N(z, \mu_{1,z}, v_{1,z})$, 其中 $\mu_{1,z}, v_{1,z}$ 为均值和方差. 此操作的详细步骤如下:

$$p(z|y) = \frac{f(y|z)N(z, \mu_{1,z}, v_{1,z})}{Z} \quad (10)$$

其中, $f(y|z)$ 表示似然函数, Z 为归一化因子, y 的后验分布为

$$\begin{cases} \hat{\mu}_{1,y} = \int y p(z|y) dy \\ \hat{v}_{1,y} = \int |y|^2 p(z|y) - |\hat{\mu}_{1,y}|^2 \end{cases} \quad (11)$$

为了保证消息的有效传递, 需要计算均值和方差, 即

$$\begin{cases} \mu_{2,z} = v_{2,z} \left(\frac{\hat{\mu}_{1,y}}{\hat{v}_{1,y}} - \frac{\mu_{1,z}}{v_{1,z}} \right) \\ v_{2,z} = \left(\frac{1}{\hat{v}_{1,y}} - \frac{1}{v_{1,z}} \right)^{-1} \end{cases} \quad (12)$$

为便于说明, 上述无偏估值的运算可简化为

$$(\mu_{2,z}, v_{2,z}) = \text{Ext} \left\{ (\hat{\mu}_{1,y}, \hat{v}_{1,y}), (\mu_{1,z}, v_{1,z}) \right\} \quad (13)$$

首先引入阻尼因子 $\beta_z(t)$ 和 $\beta_x(t)$, 再将信息传递到模块 B, t 代表网络层数. 阻尼操作如下:

$$\begin{cases} (\mu_{2,z}(t), v_{2,z}(t)) = \text{Damp}(\mu_{2,z}(t), v_{2,z}(t); \beta_z(t)) \\ (\mu_{2,x}(t), v_{2,x}(t)) = \text{Damp}(\mu_{2,x}(t), v_{2,x}(t); \beta_x(t)) \end{cases} \quad (14)$$

其中 Damp 的操作为

$$\text{Damp}(\boldsymbol{\mu}(t), \mathbf{v}(t); \beta(t)) = \begin{bmatrix} \beta(t)\boldsymbol{\mu}(t-1) + (1-\beta(t))\boldsymbol{\mu}(t) \\ \beta(t)\mathbf{v}(t-1) + (1-\beta(t))\mathbf{v}(t) \end{bmatrix} \quad (15)$$

参考矩阵 \mathbf{S} 和经过阻尼操作后的 \mathbf{z} 的无偏估计 $\boldsymbol{\mu}_{2,z}, \mathbf{v}_{2,z}$ 为模块 $\mathbf{B}\mathbf{x}$ 的输入, 我们需要假定要恢复的信号 \mathbf{x} 服从高斯伯努利分布. \mathbf{x} 的无偏估计 $\boldsymbol{\mu}_{1,x}, \mathbf{v}_{1,x}$ 为模块 $\mathbf{B}\mathbf{x}$ 的输出, 对后验平值估计的详细步骤如下:

首先计算 \mathbf{x} 的后验分布

$$\begin{cases} \hat{\boldsymbol{\mu}}_{2,x} = \hat{\mathbf{v}}_{2,x} \left[\mathbf{v}_{2,x}^{-1} \boldsymbol{\mu}_{2,x} + \mathbf{S}^H \mathbf{v}_{2,z}^{-1} \boldsymbol{\mu}_{2,x} \right] \\ \hat{\mathbf{v}}_{2,x} = \left[\mathbf{v}_{2,x}^{-1} + \mathbf{S}^H \mathbf{v}_{2,z}^{-1} \mathbf{S} \right]^{-1} \end{cases} \quad (16)$$

得到 \mathbf{x} 的后验分布后, 计算无偏估计 $\boldsymbol{\mu}_{1,x}, \mathbf{v}_{1,x}$:

$$(\boldsymbol{\mu}_{1,x}, \mathbf{v}_{1,x}) = \text{Ext} \left\{ (\hat{\boldsymbol{\mu}}_{2,x}, \hat{\mathbf{v}}_{2,x}), (\boldsymbol{\mu}_{2,x}, \mathbf{v}_{2,x}) \right\} \quad (17)$$

模块 \mathbf{C} 的输入为 \mathbf{x} 的无偏估计 $\boldsymbol{\mu}_{1,x}, \mathbf{v}_{1,x}$ 和 \mathbf{x} 的先验分布 $\boldsymbol{\mu}_{2,x}, \mathbf{v}_{2,x}$, 输出是 \mathbf{x} 的无偏估计 $\boldsymbol{\mu}_{2,x}, \mathbf{v}_{2,x}$, 此估计当作是 \mathbf{x} 的先验分布作为下一层的输入.

\mathbf{x} 的无偏估计 $\boldsymbol{\mu}_{1,x}, \mathbf{v}_{1,x}$ 和参考矩阵 \mathbf{S} 为模块 $\mathbf{B}\mathbf{z}$ 的输入, \mathbf{z} 的无偏估计 $\boldsymbol{\mu}_{1,z}, \mathbf{v}_{1,z}$ 为模块 $\mathbf{B}\mathbf{z}$ 的输出, 详细如下:

$$\begin{cases} \hat{\boldsymbol{\mu}}_{2,z} = \mathbf{S} \hat{\boldsymbol{\mu}}_{2,x} \\ \hat{\mathbf{v}}_{2,z} = \mathbf{S} \hat{\mathbf{v}}_{2,x} \mathbf{S}^H \end{cases} \quad (18)$$

得到 \mathbf{z} 的后验分布后

$$(\boldsymbol{\mu}_{1,z}, \mathbf{v}_{1,z}) = \text{Ext} \left\{ (\hat{\boldsymbol{\mu}}_{2,z}, \hat{\mathbf{v}}_{2,z}), (\boldsymbol{\mu}_{2,x}, \mathbf{v}_{2,x}) \right\} \quad (19)$$

\mathbf{z} 的无偏估计 $\boldsymbol{\mu}_{1,z}, \mathbf{v}_{1,z}$ 被当作是 \mathbf{z} 的先验分布作为下一层的输入.

4.4 基于动态超网络的 GEC 算法

在编码孔径成像系统中, 往往训练样本和测试样本之间会存在一定的偏差. 这就要求该迭代算法能够根据实际情况灵活调整, 以保证其稳定性和最优性. 引入动态超网络^[18], 根据模型对阻尼系数进行修正, 当系统的信噪比、压缩比等参数发生改变时, 它仍然能够保持良好的性能. 将这种算法称为广义期望一致超网络 (Generalized Expectation Consistent HyperNet, GEC-HNet) 算法, 其流程如图 6 所示.




图 6 GEC-HNet 流程图

将展开的主网络记作为

$$\mathbf{f}_{\text{out}} = F(\mathbf{f}_{\text{in}}; \beta) \quad (20)$$

其中, 阻尼因子 $\beta = \beta_x = \beta_z$, 根据文献[23]中的实验说明, $\beta_x = \beta_z$ 和 $\beta_x \neq \beta_z$ 时算法性能差别很小, 因此令 β_x 和 β_z 相等. 展开网络输入和输出由 \mathbf{f}_{in} 和 \mathbf{f}_{out} 代表:

$$\mathbf{f}_{\text{in}} = [\mathbf{y}, \mathbf{S}, \mathbf{v}_{1,z}(0), \boldsymbol{\mu}_{1,z}(0), \mathbf{v}_{2,x}(0), \boldsymbol{\mu}_{2,x}(0)] \quad (21)$$

$$\mathbf{f}_{\text{out}} = \{\hat{\boldsymbol{\mu}}_{1,x}(1), \dots, \hat{\boldsymbol{\mu}}_{1,x}(T)\} \quad (22)$$

其中, T 为展开网络的层数.

针对上述方法的不足, 采用动态超网络来调整阻尼因子. 将超网络记作:

$$\mathbf{g}_{\text{out}} = G(\mathbf{g}_{\text{in}}; \theta) \quad (23)$$

其中, θ 表示需要从训练数据中学习的参数, \mathbf{g}_{out} 和 \mathbf{g}_{in} 分别为超网络的输出和输入:

$$\mathbf{g}_{\text{in}} = [\tilde{\sigma}, \sqrt{\text{SNR}}] \quad (24)$$

超网络的输入为参考矩阵 \mathbf{S} 的奇异值 σ 和信噪比 SNR ^[24]. 假设 $\mathbf{S} \in \mathbb{C}^{M \times N}$, 且 $M > N$, 则

$$\boldsymbol{\sigma} = [\sigma_1, \sigma_2, \dots, \sigma_N] \quad (25)$$

$$\tilde{\sigma} = \sigma_n / \|\boldsymbol{\sigma}\|_2, n = 1, 2, \dots, N \quad (26)$$

$$\text{SNR} = \text{tr}(\mathbf{S}\mathbf{S}^H) / M \quad (27)$$

将以上输入级联并表示为

$$\mathbf{s}(t) = [\tilde{\sigma}, \sqrt{\text{SNR}}, \beta(t-1), \beta(t-2), \mathbf{v}(t)] \quad (28)$$

在此基础上引入门循环单元网络 (Gated Recurrent Unit, GRU) 结构^[18], 每次迭代的 GRU 共享相同的可训练参数, 即 $(\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_h, \mathbf{W}_o)$. 在第 t 次循环 GRU 中, GRU 以 $\mathbf{s}(t)$ 和之前状态的连接向量 $\mathbf{h}(t-1)$ 作为 GRU 输入, 进行如图 7 所示的操作.

$$\mathbf{z}(t) = \text{sigmoid}(\mathbf{W}_z[\mathbf{h}(t-1), \mathbf{s}(t-1)]) \quad (29)$$

$$\mathbf{r}(t) = \text{sigmoid}(\mathbf{W}_r[\mathbf{h}(t-1), \mathbf{s}(t)]) \quad (30)$$

$$\tilde{\mathbf{h}}(t) = \tanh(\mathbf{W}_h[\mathbf{r}(t) \odot \mathbf{h}(t-1), \mathbf{s}(t)]) \quad (31)$$

$$\mathbf{h}(t) = (1 - \mathbf{z}(t)) \odot \mathbf{h}(t-1) + \mathbf{z}(t) \odot \tilde{\mathbf{h}}(t) \quad (32)$$

$$\beta(t) = \text{Sigmoid}(\mathbf{W}_o \mathbf{h}(t)) \quad (33)$$

其中, $\mathbf{r}(t)$ 为控制重置的门控, \tanh 函数定义为

$$\tanh(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (34)$$

其中, $[\cdot]$ 代表级联操作; \odot 代表 Hadamard 相乘; $(1 - \mathbf{z}(t))$ 项的目的是去掉 $\mathbf{h}(t-1)$ 在第 $(t-1)$ 次所传递的一些维度信息, 其中 $\mathbf{z}(t)$ 是上一状态与当前状态的更新参数.




图7 第t个GRU结构

经过以上操作,GRU可以通过上一次迭代产生的阻尼因子 $\beta(t)$ 和 $v(t)$ 去调控下一次迭代产生的阻尼因子,从而使网络能够更快收敛.

超网络损失函数为

$$L(G(\mathbf{g}_m; \theta)) = \frac{1}{L} \sum_{l=1}^L \sum_{t=1}^T \|\mathbf{x}^l - \hat{\boldsymbol{\mu}}_{l,\mathbf{x}}^t(t)\|_2^2 \quad (35)$$

其中, \mathbf{x}^l 为1个训练数据,训练时通过最小化损失函数来学习最优参数.

5 仿真实验结果与分析

本节使用3组实验来对本文所提算法的性能进行验证. 首先,在不同的信噪比条件下,将其他算法与本文算法进行对比. 其次,对不同压缩比下的图像质量进行比较. 然后,对比6种算法在存在相位误差时的成像结果. 最后,定量分析6种算法对于误差的鲁棒性和成像性能.

在本节中,训练样本个数为4800个,样本的格式都是 (\mathbf{y}, \mathbf{x}) . 这里 \mathbf{y} 是回波,通过式(6)产生. \mathbf{x} 表示原始图像的散射系数,使 \mathbf{x} 的元素遵循伯努利-高斯分布,表示为

$$p(x_i) = (1 - \rho)\delta(x_i) + \rho N(x_i; 0, \rho^{-1}) \quad (36)$$

式中, x_i 表示向量 \mathbf{x} 的元素; ρ 表示稀疏度,在训练集中,该参数范围为 $[0.3, 0.8]$.

在tensorflow框架下,使用0.05的学习速度,利用自适应矩估计对参数进行优化,设置层数 $T=10$ 对参数进行训练,使损失函数达到最小. 微波计算像系统的参数如表1所示.

成像实验的结果用相对成像误差(Relative Imaging Error, RIE)来评估,RIE表示如下:

表1 微波计算成像系统参数

参数名称	符号	参数值
中心频率/GHz	f_c	10.0
带宽/GHz	B	1.0
脉冲宽度/ns	Δt	100.0
超材料单元个数	Q	41×41
超材料单元间距/cm	D	1.5
成像区域划分网格数	M	100×100
成像网格尺寸/m	Δm	0.05×0.05
成像距离/m	d	6.0

$$\text{RIE} = 20 \log \left(\frac{\|\hat{\mathbf{x}} - \mathbf{x}\|_2}{\|\mathbf{x}\|_2} \right) \quad (37)$$

式中, $\hat{\mathbf{x}}$ 和 \mathbf{x} 分别表示原始信号和恢复信号.

5.1 噪声鲁棒性

本实验是评价本文所提算法在噪声条件下的成像效果. 为此,将信噪比设置为 $-5 \sim 30$ dB,压缩比设置为4. 本文用图8所示图像作为原始图像. 对比算法为GEC、GEC-Net、RWF、TAF和HIO. 图9和图10分别给出不同信噪比下6种算法的成像结果. 从图中能明显看出将信噪比设置为10 dB时,3种传统算法无法成像,而本文方法可以将目标轮廓显示出来. 在信噪比为25 dB时,6种算法均能较好地反映出目标的大致轮廓,本文所提出的算法能较准确地重建出目标图像.

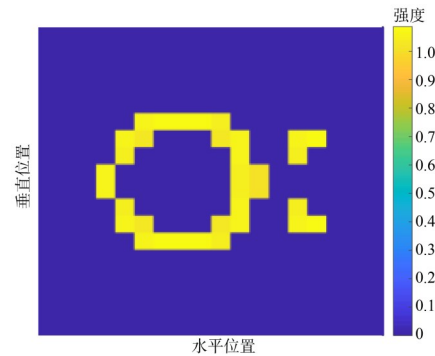


图8 原始目标

为了更加直观地展示各种算法之间的差别,对不同算法在 $-5 \sim 30$ dB时的相关成像误差进行量化分析,图11给出了6种算法在不同信噪比下的RIE曲线. 可以看出,在信噪比相同的情况下,所提方法的RIE最低. 与传统的RWF、TAF、HIO相比,GEC、GEC-Net、GEC-HNet等传统算法的相位的抗噪声性能更好,其中,GEC-HNet具有较强的鲁棒性.

图12给出了GEC、GEC-Net、GEC-HNet等不同算法的收敛性比较. 可以看出,GEC-HNet算法的收敛性最好,MSE值随迭代次数快速下降,当迭代次数为4时已趋于平稳,表明GEC-HNet算法更加稳定且收敛速度更快.

5.2 不同压缩比测量下的重建

压缩比也会影响系统成像性能,由测量次数与成

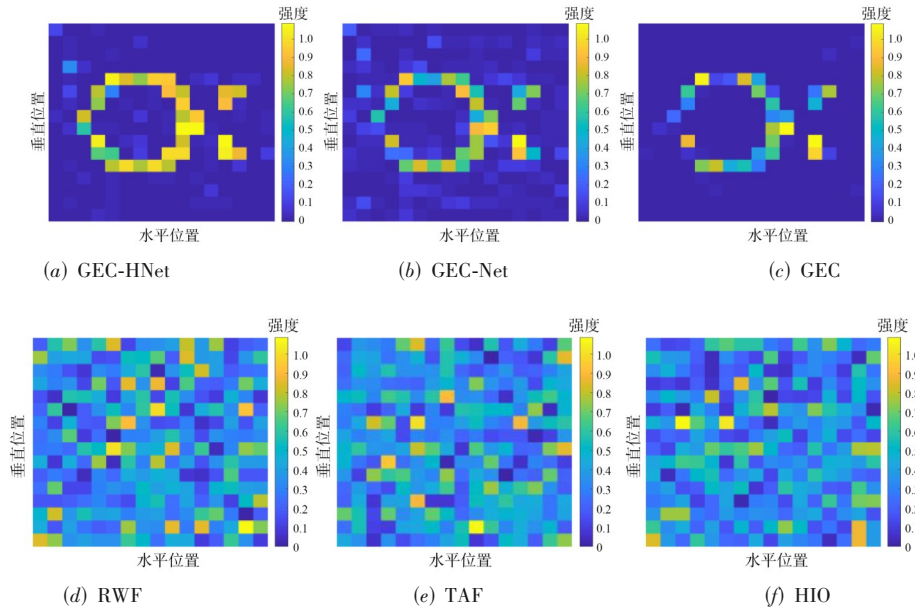


图9 SNR=10 dB时的成像结果对比




图10 SNR=25 dB时的成像结果对比




图11 不同信噪比条件下的RIE变化

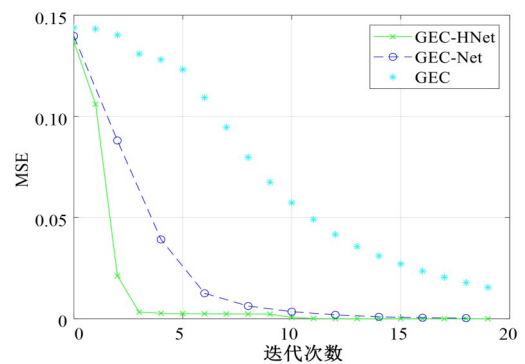


图12 GEC、GEC-Net、GEC-HNet的收敛性比较

像网格的数量之比来计算,表达式为

$$\gamma = \frac{N}{L} \quad (38)$$

其中, N 为测量次数, L 为目标所在成像网格的数量.

当压缩比提高时,成像效果也会得到提升,但是占

用的资源也将增加. 图 13 和图 14 分别显示了将压缩比设置为 3 和 1.2 时 6 种算法的结果. 可以看到,传统算法的图像质量随着压缩比的降低而变差, GEC-HNet 算法表现良好.

为了对压缩比降低后的成像质量进行量化分析,绘

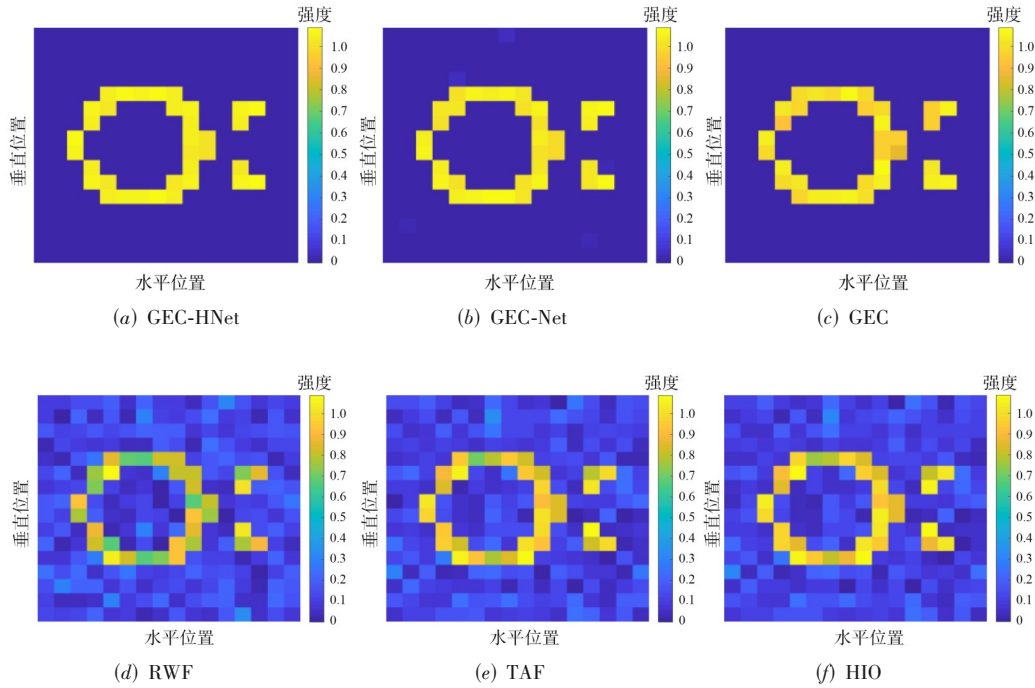


图 13 压缩比为 3 时不同方法的成像结果对比




图 14 压缩比为 1.2 时的成像结果对比

制了不同压缩比下6种算法的RIE曲线,如图15所示.




图15 不同压缩比测量下的RIE变化

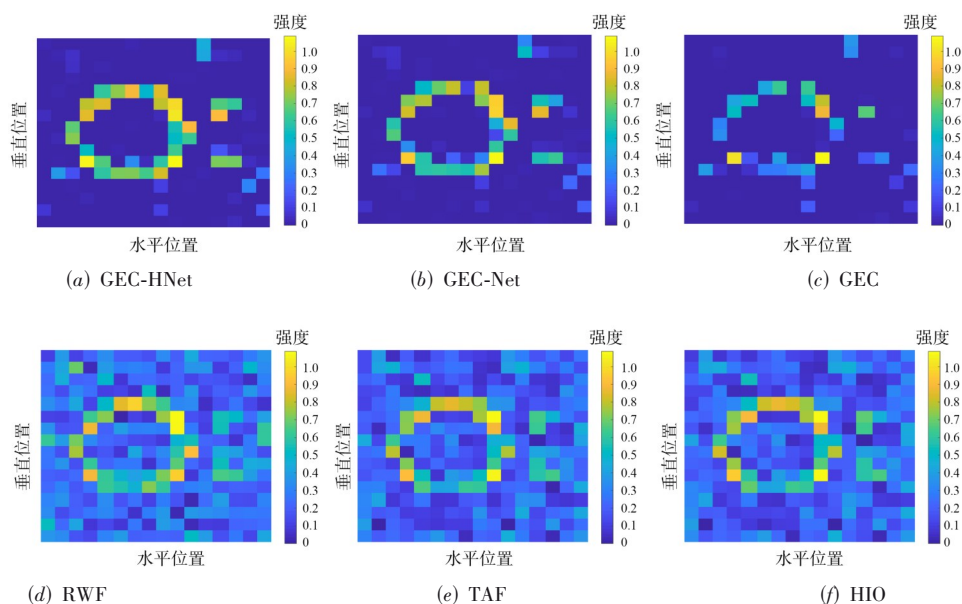


图16 存在相位误差时不同方法的成像结果对比

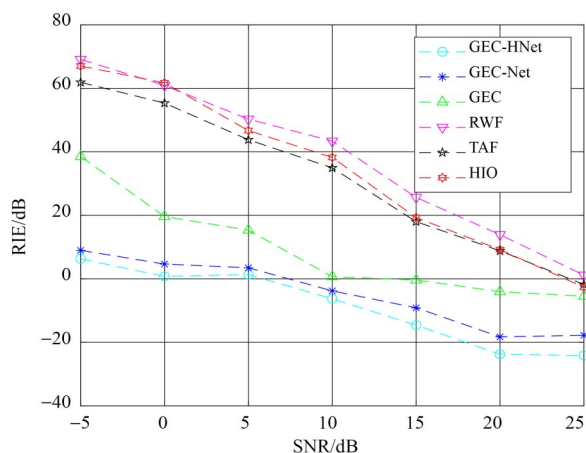


图17 存在相位误差的RIE变化

结果表明,本文提出的算法在不同压缩比下均具有最小的相对成像误差.该方法显著降低了可恢复压缩比.

5.3 存在相位误差的成像性能

接下来研究各种算法在有相位误差下的重建性能,即存在相位误差的条件下,不同方法的成像性能所受影响程度.图16给出在信噪比为25 dB时存在相位误差条件下的不同方法成像结果对比,从图中可以看出存在相位误差时,RWF、TAF和HIO等算法的成像效果较差,而本文方法可以显示出目标轮廓.

为了更加直观的显示本文方法在存在相位误差时的成像性能,分别计算不同算法在信噪比从-5~25 dB条件下的RIE,并且绘制了6种算法在不同信噪比条件下的RIE变化图,如图17所示.在相同信噪比条件下,本文算法RIE最小,效果最优.

6 结论

为了解决IMA-MCI系统在有噪声及相位误差情况下的成像性能不佳的情况,本文提出了基于深度展开网络的相位恢复算法.首先,分析了在IMA-MCI系统中相位误差的影响,探讨其对成像质量的影响因素.然后,从理论角度对IMA-MCI系统进行了建模,推导出了相位恢复的成像方程并构建算法流程.最后,通过仿真实验,将该算法与其他经典相位恢复方法进行了比较.结果表明,该算法在成像性能和鲁棒性方面具有显著优势.

目前,基于信息超材料的微波计算成像技术仍处于发展初期,在实际工程应用中还面临许多挑战.本文算法对回波信号的幅度要求相对准确,但在应用过程中,

目标常常会发生未按预期或理想状态进行的移动或变化,这导致接收到的回波幅度信息难免有偏差,从而影响成像效果.因此,这一问题亟待进一步研究.

参考文献

- [1] 韩家奇,田顺成,易浩,等.基于信息超材料的高性能微波计算成像系统[J].雷达学报,2021,10(2):288-295.
HAN J Q, TIAN S C, YI H, et al. High-performance microwave computational imaging system based on information metamaterials[J]. Journal of Radars, 2021, 10(2): 288-295. (in Chinese)
- [2] PATELV M, MAITJ N, PRATHERD W, et al. Computational Millimeter Wave Imaging: Problems, progress, and prospects[J]. IEEE Signal Processing Magazine, 2016, 33(5): 109-118.
- [3] 崔铁军,吴浩天,刘硕.信息超材料研究进展[J].物理学报,2020,69(15):175-187.
CUI T J, WU H T, LIU S. Research progress of information metamaterials[J]. Acta Physica Sinica, 2020, 69(15): 175-187. (in Chinese)
- [4] 王爱业,潘安,马彩文,等.相位恢复算法:原理、发展与应用(特邀)[J].红外与激光工程,2022,51(11):3788/IR-LA20220402.
WANG A Y, PAN A, MA C W, et al. Phase retrieval algorithms: Principles, developments and applications(invited) [J]. Infrared and Laser Engineering, 2022, 51(11): 3788/IR-LA20220402. (in Chinese)
- [5] FIENUP J R. Phase retrieval algorithms: A comparison[J]. Applied Optics, 1982, 21(15): 2758-2769.
- [6] CANDÈS E J, LI X D, SOLTANOLKOTABI M. Phase retrieval via wirtinger flow: Theory and algorithms[J]. IEEE Transactions on Information Theory, 2015, 61(4): 1985-2007.
- [7] ZHANG H S, ZHOU Y, LIANG Y B, et al. Reshaped wirtinger flow and incremental algorithm for solving quadratic system of equations[EB/OL]. (2016-10-25)[2023-05-25]. <http://arxiv.org/abs/1605.07719>.
- [8] WANG G, GIANNAKIS G B, ELDAR Y C. Solving systems of random quadratic equations via truncated amplitude flow[J]. IEEE Transactions on Information Theory, 2018, 64(2): 773-794.
- [9] HE H T, WEN C K, JIN S. Generalized expectation consistent signal recovery for nonlinear measurements[C]//2017 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE, 2017: 2333-2337.
- [10] 吴靖,叶晓晶,黄峰,等.基于深度学习的单帧图像超分辨率重建综述[J].电子学报,2022,50(9):2265-2294.
WU J, YE X J, HUANG F, et al. A review of single image super-resolution reconstruction based on deep learning[J]. Acta Electronica Sinica, 2022, 50(9): 2265-2294. (in Chinese)
- [11] 化青龙,魏晨曦,张云,等.基于自监督复数域深度学习网络的SAR有源压制干扰抑制方法[J].电子学报,2023,51(4):965-974.
HUA Q L, WEI C X, ZHANG Y, et al. Active jamming suppression for SAR images based on self-supervised complex-valued deep learning[J]. Acta Electronica Sinica, 2023, 51(4): 965-974. (in Chinese)
- [12] 左超,冯世杰,张翔宇,等.深度学习下的计算成像:现状、挑战与未来[J].光学学报,2020,40(1):0111003.
ZUO C, FENG S J, ZHANG X Y, et al. Deep learning based computational imaging: Status, challenges, and future[J]. Acta Optica Sinica, 2020, 40(1): 0111003. (in Chinese)
- [13] 王杰,魏振东,王启江,等.基于事件信息与深度学习的高动态范围三维重建[J].数据采集与处理,2024,39(2):337-347.
WANG J, WEI Z D, WANG Q J, et al. High dynamic range 3D reconstruction based on event information and deep learning[J]. Journal of Data Acquisition and Processing, 2024, 39(2): 337-347. (in Chinese)
- [14] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Machine learning of linear differential equations using Gaussian processes[J]. Journal of Computational Physics, 2017, 348: 683-693.
- [15] 申滨,涂媛媛,阳建,等.基于卷积特征提取及深度降噪网络的大规模MIMO系统信号检测[J].信号处理,2024,40(6):1030-1040.
SHEN B, TU Y Y, YANG J, et al. Massive MIMO system signal detection based on convolutional feature extraction and deep denoising network[J]. Journal of Signal Processing, 2024, 40(6): 1030-1040. (in Chinese)
- [16] WANG F, BIAN Y M, WANG H C, et al. Phase imaging with an untrained neural network[J]. Light: Science & Applications, 2020, 9: 77.
- [17] NAIMIPOUR N, KHOBABI S, SOLTANALIAN M. UPR: A model-driven architecture for deep phase retrieval[C]//2020 54th Asilomar Conference on Signals, Systems, and Computers. Piscataway: IEEE, 2020: 205-209.
- [18] 温裕广.基于超材料孔径的微波计算成像技术研究[D].秦皇岛:燕山大学,2023.
WEN Y G. Research on Mmicrowave Computational Imaging Technology Based on Metamaterial Aperture[D]. Qinhuangdao: Yanshan University, 2023.
- [19] CUI T J, QI M Q, WAN X, et al. Coding metamaterials, digital metamaterials and programmable metamaterials[J].

Light: Science & Applications, 2014, 3(10): e218.

- [20] LUO Z L, CHENG Y Q, QIN Y L, et al. Computational imaging at microwave frequency based on reprogrammable metasurface[C]//2018 International Conference on Microwave and Millimeter Wave Technology. Piscataway: IEEE, 2018: 1-3.
- [21] HE H T, JIN S, WEN C K, et al. Model-driven deep learning for physical layer communications[J]. IEEE Wireless Communications, 2019, 26(5): 77-83.
- [22] WANG C J, WEN C K, TSAI S H, et al. Phase retrieval using expectation consistent signal recovery algorithm based on hypernetwork[J]. IEEE Transactions on Signal Processing, 2021, 69: 5770-5783.
- [23] WANG C J, WEN C K, TSAI S H L, et al. Phase retrieval with learning unfolded expectation consistent signal recovery algorithm[J]. IEEE Signal Processing Letters, 2020, 27: 780-784.
- [24] WANG C J, WEN C K, TSAI S H, et al. Decentralized expectation consistent signal recovery for phase retrieval[J]. IEEE Transactions on Signal Processing, 2020, 68: 1484-1499.

作者简介



史洪印 男, 1976年4月出生, 山东菏泽人. 北京建筑大学电气与信息工程学院教授、博士生导师. 主要研究方向为雷达成像与目标检测.
E-mail: shihongyin@bucea.edu.cn



彭毓晗 男, 2000年4月出生, 河北承德人. 北京建筑大学电气与信息工程学院控制科学与工程专业硕士. 主要研究方向为微波计算成像系统性能分析及成像算法.
E-mail: m18631425969@163.com



温裕广 男, 1998年8月出生, 山西大同人. 2023年毕业于燕山大学电子信息专业. 主要研究方向为基于超材料孔径的微波计算成像技术研究.
E-mail: 1667376537@qq.com