

物理模型引导的智能相位成像

刘振^{1,2}, 朱昊¹, 周游^{1,3}, 马展¹, 曹汛¹

(1. 南京大学电子科学与工程学院, 江苏 南京 210023;

2. 南京大学计算机科学与技术系, 江苏 南京 210023; 3. 南京大学医学院, 江苏 南京 210093)

摘要: 隐式神经表示使用神经网络刻画了信号坐标到其属性的映射, 通过将正向物理过程引入误差函数的设计中, 可被用于求解各种逆问题, 应用前景广阔。然而, 对隐式神经表示的网络参数进行随机初始化会导致优化速度慢、求解精度低, 因此, 提出使用元学习算法为隐式神经表示提供一个具有强先验的初始化参数, 从而提升求解逆问题时的优化速度和求解精度。针对无透镜相位成像这一重要问题, 基于快照式无透镜感知模型提出一种智能相位成像方法, 将光学衍射传播理论引入隐式神经表示的误差函数设计中, 能够消除传统深度学习算法对大规模数据集的依赖, 仅需要传感器记录的单张强度图像, 即可实现对样本的高精度相位恢复。此外, 通过在网络初始化中引入元学习模型, 进一步提升网络训练的效率和精度。数值仿真结果表明, 与传统方法相比, 所提方法能够获得 11 dB 以上的峰值信噪比 (PSNR, peak signal-to-noise ratio) 提升; 在真实数据中的实验结果表明, 所提方法重建出的相位图像更加清晰, 伪影更少。

关键词: 隐式神经表示; 物理模型; 相位成像; 元学习; 自监督学习

中图分类号: TN26

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2023.00345

Intelligent phase imaging guided by physics models

LIU Zhen^{1,2}, ZHU Hao¹, ZHOU You^{1,3}, MA Zhan¹, CAO Xun¹

1. School of Electronic Science and Engineering, Nanjing University, Nanjing 210023, China

2. Department of Computer Science and Technology, Nanjing University, Nanjing 210023, China

3. Medical School, Nanjing University, Nanjing 210093, China

Abstract: Implicit neural representation characterizes the mapping between the signal's coordinate to its attributes, and has been widely used in the optimization of inverse problems by embedding the physics process into the loss function. However, the implicit neural representation is suffering the low convergence speed and accuracy from the random initialization of the network parameters. The meta-learning algorithm for providing implicit neural representation with a strong prior of network parameters was proposed, thus enhancing the optimization efficiency and accuracy for solving inverse problems. To address the important issue of lens less phase imaging, an intelligent method on phase imaging was proposed based on the snapshot lens less sensing model. By embedding the optical diffraction propagation theory into the design of loss function for implicit neural representation, the dependency of large-scale labelled dataset in traditional deep learning-based methods was eliminated and accurate phase image from a single diffraction measurement image was provided. Furthermore, the meta-learning model was introduced for initializing network to further improve the efficiency and accuracy of network training. Numerical simulation results show that the proposed method can achieve a PSNR improvement of more than 11 dB compared to the conventional method. The experimental results in real data show that the phase image reconstructed by the proposed method is clearer and has fewer artifacts.

Key words: implicit neural representation, physics model, phase imaging, meta learning, unsupervised learning

收稿日期: 2022-09-06; 修回日期: 2023-06-01

通信作者: 曹汛, caoxun@nju.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62025108, No.62071219, No.62101242)

Foundation Items: The National Natural Science Foundation of China (No.62025108, No.62071219, No.62101242)

0 引言

目前,深度学习已被广泛应用于解决计算成像中的各种逆问题,如数字全息^[1-3]、计算鬼影成像^[4-5]、相位恢复^[6-7]等。这些方法通常利用一个神经网络模拟成像逆过程^[8],然后采用监督学习策略反向求解,即使用大量带标签的训练数据优化神经网络参数,以获得一个从对象空间到目标图像空间的通用映射函数^[9]。这种数据驱动的方法对训练集的数据量有着较高的要求。然而在显微领域,研究人员通常难以获取大量训练样本的真值图像用于网络训练,这限制了神经网络的泛化能力^[10],导致网络在新样本上的效果欠佳。研究者们提出了一系列融合物理知识的自监督学习网络来尝试解决这一问题^[11-14]。其中,物理增强深度神经网络(PhysenNet, physics-enhanced deep neural network)^[11]将物理模型与未训练的卷积神经网络相结合,以单张衍射测量图像为输入,可训练重建出显微样本的相位图像。而笔者团队所提出的衍射神经辐射场(DNF, diffractive neural field)^[14]方法则利用多层感知机网络直接将待观测物体的空域坐标作为输入,将振幅与相位作为输出,并结合物理模型来实现网络的自监督训练优化。与聚焦于建模物理成像逆过程的PhysenNet不同,DNF直接构建了从坐标空间到振幅相位的映射,因此其网络参数量远小于PhysenNet。然而,原始DNF方法需要多次强度测量来优化训练自监督网络,限制了成像速度,不利于一些动态观测应用,并且DNF采用随机初始化的网络参数,不包含任何先验信息,导致其训练优化性能上限低。

与传统的光学显微镜不同,无透镜成像无须采用任何光学镜头,仅通过图像传感器实现对样本信息的感知。由于无透镜成像能够绕开成像透镜数值孔径(NA, numerical aperture)引入的光学带宽限制,同时实现高分辨与大视场成像,因此在显微领域得到了广泛关注。然而,传统图像传感器仅能记录光信号的强度信息,如何从中精确恢复样本的复振幅信息是无透镜成像中的一个经典难题。相干衍射成像方法是一类普遍采用的无透镜成像模型^[7,11,14],通过采集物体在相干光照明下的多张衍射测量图像并结合相位恢复算法来重构物体的复振幅图像。笔者团队之前的DNF工作^[14]就是基于相干衍射成像模型,通过改变样本到传感器的距离采集多张强度图像,并利用自监督学习重构样本的强度和相位信息。然而多次测

量的方法会限制无透镜成像的速度,使其难以应用于快速生物活动的观测。为了实现动态观测,研究者们提出使用快照式无透镜感知结合相位恢复算法的方式实现透明样本的相位成像^[15]。然而,从单次强度测量中恢复样本的相位信息是一个欠定非凸问题,传统相位恢复算法,如GS(Gerchberg-Saxton)算法^[16-17]、基于凸优化求解的算法^[18-19],往往难以取得较好的重建效果。

近年来,隐式神经表示在逆问题求解中得到了广泛的应用。不同于传统基于数组形式的显示表示,隐式神经表示使用神经网络建立信号属性基于坐标的表示,网络输入为坐标,输出为属性值,通常使用多层感知机(MLP, multilayer perceptron)网络描述坐标到属性的关系。与离散形式的数组表示相比,隐式神经表示具有连续性强的优点,与传统卷积神经网络相比,隐式神经表示具有参数量少、量级轻等优点。针对无透镜相位成像这一重要问题,本文基于快照式无透镜感知模型,提出一种基于自监督网络的智能相位成像方法,将光学衍射传播理论引入隐式神经表示的设计中,以消除传统深度学习方法对大规模数据集的依赖,克服显微领域中大量具有真值的训练样本难以获取的问题,仅需要单张强度图像作为输入,即可实现对样本相位信息的高精度恢复。进一步地,本文利用元学习^[20]对神经网络的初始参数进行优化,以提升显微样本的相位重建效率和精度。具体来说,利用多层感知机网络构建待观测样本的空域坐标到其相位信息的映射,并结合相干成像的物理过程,实现自监督地训练优化网络参数。此外,本文利用元学习learning to learn的思想^[20],先使用计算机仿真构建一个大规模的快照式相位成像任务集,然后在该数据集上使用模型无关的元学习(MAML, model-agnostic meta-learning)算法^[21]对模型进行元学习训练,以获取网络模型的初始参数,可以为待观测样本的表示提供一个强大的先验^[22],能够获得更好的成像效果。最后,在仿真数据和真实数据上的实验结果都表明,相比传统迭代重建方法,本文的方法在相位成像质量上有显著的提升。本文的主要贡献如下。

1) 针对 DNF 工作中隐式神经表示优化速度慢、精度低的问题,本文提出使用元学习获得一个具有强先验的网络初始参数,从而提升逆问题求解时的优化速度与精度。

2) 针对无透镜相位成像这一重要问题, 本文提出物理模型引导的智能相位成像模型, 实现了基于单曝光强度图像的相位重建, 既可以减少衍射测量采集的时间, 又消除了传统深度学习方法对大规模数据集的依赖, 实现了对样本相位的智能高精度重建。

1 成像模型与网络重构

1.1 快照式无透镜感知模型

首先描述快照式无透镜感知模型。本文采用均匀入射的相干平行光照射待观测的相位物体 $\phi(x, y; 0)$, 相位物体所在的位置处会形成一个复数场 $U(x, y; 0) = A \exp[i\phi(x, y; 0)]$, 其中复数场的强度 A 为一个常数, 通过归一化, 它在成像过程中的影响可被消除, 因此本文将 A 简化为 1, 那么复数场被简化为 $U(x, y; 0) = \exp[i\phi(x, y; 0)]$ 。根据光的衍射传播理论可知, 距离相位物体 $z = d$ 处的光波复数场为

$$U(x, y; d) = \text{PSF}_d * U(x, y; 0) \quad (1)$$

其中, PSF_d 为菲涅尔衍射 (Fresnel diffraction) 传播距离为 d 的点扩散函数 (PSF, point spread function), $*$ 为卷积运算符号。由于图像传感器只能记录光波的强度, 所以距离相位物体 $z = d$ 处的图像传感器上实际采集到的衍射测量图像为

$$I(x, y; d) = |U(x, y; d)|^2 \quad (2)$$

式 (2) 可进一步抽象化为 $H(\phi(x, y; 0)) = I(x, y; d) = |\text{PSF}_d * \exp[i\phi(x, y; 0)]|^2$, 其中 $H(\cdot)$ 为相位物体 ϕ 到衍射测量图像 I 之间的映射函数, H 可表示相位成像的物理过程。最终相位成像的目标为, 给定由图像传感器采集到的衍射测量图像 $I(x, y; d)$, 求解待观测的相位物体 $\phi(x, y; 0)$ 。

1.2 自监督智能相位成像模型

传统基于监督学习的卷积神经网络 (CNN, convolutional neural network) 方法通常采用 U-Net^[23] 来重建相位图像, 其网络的输入为衍射测量图像 I , 输出为重建的相位图像 ϕ , 并需要利用大规模的带标签数据优化它的网络参数。然而在实际情况下, 采集大量的衍射测量图像及其对应的真值相位图像非常困难, 因此, U-Net 的泛化能力会受限于训练数据集的规模, 经过监督训练后的 U-Net 仅对与训练集具有相同先验的对象具有良好的相位重建效果。

本文提出的自监督训练模型则不需要任何真值相位图像, 且仅需要单张衍射测量图像便可即时地进行相位重建。具体地, 本文使用 MLP 网络直

接构建待观测的相位物体的空域坐标到其相位的隐式映射 $g_\theta : (x, y) \rightarrow \phi(x, y; 0)$, 其中 θ 表示 MLP 网络中的权值和偏置, 相比传统方法中的 CNN, MLP 网络具有参数量少、量级轻等优点。物理模型引导的智能相位成像模型训练流程如图 1 所示, 本文使用的 MLP 网络由 8 个隐藏层组成, 每个隐藏层包含 256 个神经元, 并使用线性修正单元 (ReLU, rectified linear unit) 作为激活函数 (黑色箭头), 输出层则采用 Sigmoid 作为激活函数 (蓝色箭头)。MLP 网络的输入为相位物体的空域坐标, 输出为相位, MLP 网络的优化目标为

$$\theta^* = \arg \min_{\theta} \|H(g_\theta(x, y))\|_2^2 \quad (3)$$

本文通过将 MLP 网络模型 g_θ 与相位成像的物理过程 H 结合来训练优化网络: 首先将神经网络重建出的相位 $g_\theta(x, y)$ 经过相位成像过程得到重建的衍射测量 $H(g_\theta(x, y))$, 然后用重建的衍射测量与真实的衍射测量 I 的均方误差 (MSE, mean square error) 作为损失函数, 从而实现自监督地训练优化网络模型参数 θ , 最终得到的重建相位为 $\tilde{\phi} = g_\theta(x, y)$ 。MLP 网络由于趋于学习低频的函数^[24], 在拟合高频函数方面表现不佳, 因此为了更好地拟合空域坐标到相位图像高频分量的映射, 本文在空域坐标输入 MLP 网络之前先使用位置编码 (PE, positional encoding)^[25] 将其映射到一个高维的傅里叶空间

$$\text{PE}(x, y) = \{\cos(2\pi s \sigma_i x), \sin(2\pi s \sigma_i x)\} \cup \{\cos(2\pi s \sigma_i y), \sin(2\pi s \sigma_i y)\} \quad (4)$$

其中, $\sigma_i \sim \mathcal{N}(0, 1)$, 从标准高斯分布中随机采样, s 是一个比例因子。在本文数值仿真实验和真实数据实验中, $L = 20$, $s = 6$ 。

在实际实现中, PSF 卷积核太大, 从而导致相位成像的物理过程 H 的计算非常耗时。为了提升训练效率, 本文采用角谱法代替该卷积操作, 即将 PSF 在空域中的卷积运算转化为相干传递函数 (CTF, coherent transfer function) 在傅里叶域中的点乘运算, 这使得计算复杂度从 $O(N^2)$ 降低到了 $O(N \lg N)$ 。

$$\text{CTF}_d = e^{i \cdot d \sqrt{k_0^2 - k_x^2 - k_y^2}}, \text{PSF}_d = \mathcal{F}^{-1}(\text{CTF}_d) \quad (5)$$

其中, $\mathcal{F}(\cdot)$ 表示傅里叶变换, (k_x, k_y) 表示傅里叶空间中的坐标, $k_0 = 2\pi / \lambda$ 表示波数, 这里 λ 为入射光源的波长。最终, 自监督模型的损失函数为

$$\mathcal{L} = \|\mathcal{F}^{-1}(\mathcal{F}(g_\theta(x, y)) \cdot \text{CTF}_d) - I(x, y; d)\|_2^2 \quad (6)$$

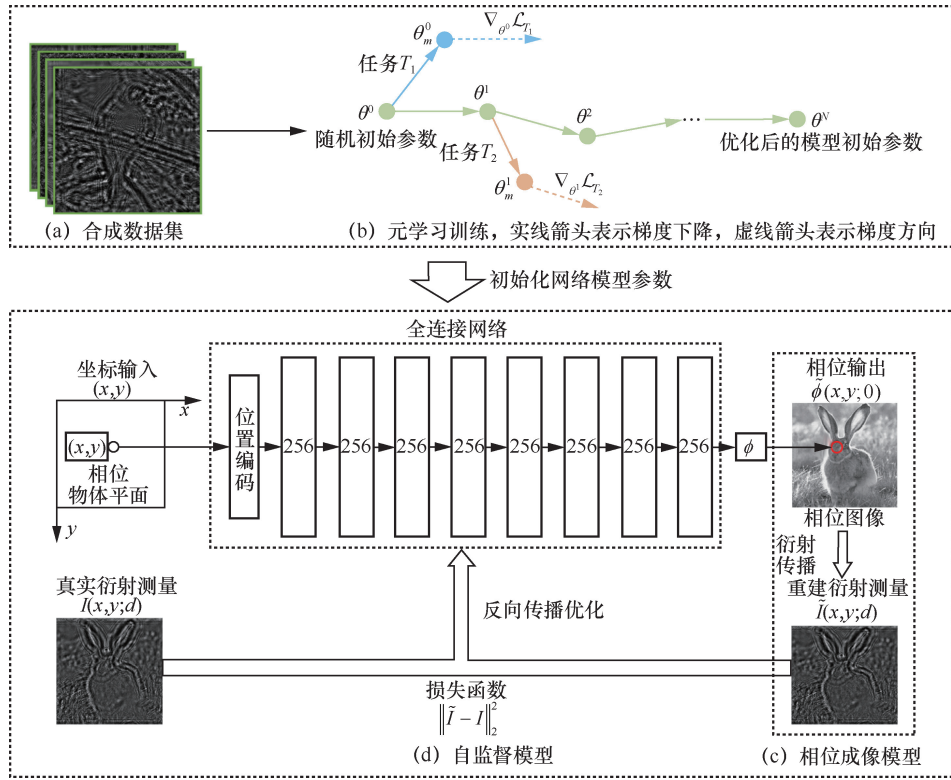


图 1 物理模型引导的智能相位成像模型训练流程

1.3 元学习训练

元学习是一种从多个学习任务上获取经验，从而提升模型在未来任务上的学习性能的机器学习范式，具有提高计算模型精度的^[20]优点。本文使用元学习提升第 1.2 节智能相位成像算法的重建精度。如图 1 所示，对于给定的合成数据集，利用 MAML 算法获取 MLP 网络的初始参数 θ ，然后使用给定的单张显微衍射测量图像对 θ 进行优化，从而重建出更高质量的相位信息。

首先，假设具有相同成像物理参数（如照明光波长、衍射距离、分辨率等）的所有快照式相位成像任务都服从一个特定的分布 \mathcal{T} ，不同任务间仅是待观测的相位物体不同。然后，定义一个快照式相位成像任务集 $T = \{T_1, T_2, \dots, T_N\}, T_i \sim \mathcal{T}$ ，其中每一个相位成像任务 T_i 的待观测相位物体为 ϕ_i ，相应的衍射测量为 $I_i = H(\phi_i)$ ，因此由式(3)和式(6)可得，在给定 MLP 网络模型 g_θ 的情况下，任务 T_i 的损失函数为

$$\mathcal{L}_{T_i} = \|H(g_\theta(x, y)) - I_i\|_2^2 \quad (7)$$

令 θ_0^i 表示任务 T_i 上模型的初始参数， θ_j^i 表示任务 T_i 上模型进行了 j 次梯度下降更新后的参数，设学习率为 α ，则基于随机梯度下降 (SGD, stochastic

gradient descent) 更新的参数为

$$\theta_{j+1}^i = \theta_j^i - \alpha \nabla_{\theta_j^i} \mathcal{L}_{T_i}(g_{\theta_j^i}) \quad (8)$$

这里本文将 MLP 网络模型 $g_{\theta_0^i}$ 在任务 T_i 上进行 m 次梯度下降的过程称为内循环。

然后，采用 MAML 算法优化网络的初始参数 θ ，用于相位成像的元学习训练算法见算法 1，其优化目标为

$$\theta^* = \arg \min_{\theta} \sum_{T' \sim \mathcal{T}, T_i' \in T'} \mathcal{L}_{T_i'}(g_{\theta_m}) \quad (9)$$

其中， T_i 表示一个新的快照式相位成像任务集。元学习的目标是使得使用元学习训练的初始参数模型能够在新任务上表现出最优的性能。将优化模型初始参数的步骤称为外循环：每次采样一个任务 $T_i \in \mathcal{T}$ ，在该任务上执行完内循环后，使用随机梯度下降法来优化更新模型的初始参数

$$\theta = \theta - \beta \nabla_{\theta} \mathcal{L}_{T_i}(g_{\theta_m}) \quad (10)$$

其中， β 为更新步长，外循环结束后所得到的参数 θ 即经过元学习优化的模型初始参数。

算法 1 用于相位成像的元学习训练算法

输入 相位成像任务集 $T = \{T_1, T_2, \dots, T_N\}$ ，内循

环、外循环更新步长 α, β , 模型 g , 模型初始参数 θ

输出 优化后的模型初始参数 θ

随机初始化模型初始参数 θ

for $i = 0, 1, \dots, N$

 采样一个任务 T_i , 初始化模型参数 $\theta_0^i = \theta$

 for $j = 0, 1, \dots, m-1$

 重建待观测物体: $g_{\theta_j^i}(x, y)$

 重建衍射测量值: $\tilde{I}_{T_i}(x, y; d) = \mathcal{F}^{-1}(\mathcal{F}(g_{\theta_j^i}(x, y)) \cdot \text{CTF}_d)$

 损失函数: $\mathcal{L}_{T_i}(g_{\theta_j^i}) = \|\tilde{I}_{T_i}(x, y; d) - I_{T_i}(x, y; d)\|_2^2$

 利用梯度下降法更新模型参数:

$\theta_{j+1}^i = \theta_j^i - \alpha \nabla_{\theta_j^i} \mathcal{L}_{T_i}(g_{\theta_j^i})$

 end for

 更新模型初始参数: $\theta = \theta - \beta \nabla_{\theta} \mathcal{L}_{T_i}(g_{\theta_m^i})$

end for

2 实验结果

2.1 模型实现

本文使用 PyTorch 库实现 MLP 网络模型, 并采用 Adam 优化器^[26]优化网络的权重和偏置, 设置初始学习率为 0.001, 在 3 000、6 000 次迭代后, 将学习率分别衰减为原来的 0.1。元学习训练中的内循环和外循环均采用随机梯度下降法来更新网络参数, 更新步长 α 、 β 均为 0.001。本文所有实验均在一台服务器上运行, 其中 CPU 型号为 Intel(R) Xeon(R) Gold 6226R, GPU 型号为 40 GB 显存的 NVIDIA A100; GS 重建实验使用 MATLAB 2021b。

2.2 仿真数据

仿真实验采用大小为 400 px × 400 px 的灰度图像作为待观测物体的真值相位, 然后根据菲涅尔衍射传播理论计算得到单张强度图像, 即训练数据。相位成像过程中, 入射光源的中心波长 $\lambda = 632.8$ nm, 相位样本到传感器探测面的衍射距离 $d = 22.3$ mm。

首先, 构建一个仿真数据集, 并在该数据集上使用元学习训练优化出一个较好的网络初始参数。因此, 本文从 ImageNet^[27]数据集中随机抽取 8 000 张图片, 然后将每张图片转化为 400 px × 400 px 的灰度图像并作为待观测的相位物体, 再根据相同的相位成像过程计算得到相应的单张强度图像。每张强度

图像对应一个相位成像任务的训练数据, 如此便构造了一个规模大小为 8 000 的快照式相位成像任务集。在该任务集上, 元学习训练的外循环执行了 8 000 次梯度下降来更新模型初始参数, 其中每个内循环执行两次梯度下降。元学习训练结束后, 使用优化后的网络参数来初始化模型, 然后在新的合成单张强度测量图像上重建相位图像。

合成数据相位恢复结果对比如图 2 所示, 对比了本文所提出的自监督智能相位成像算法、传统的 GS 算法^[16-17], 以及不使用元学习训练(网络参数随机初始化)的自监督网络模型。在没有其他先验知识时, GS 算法从单张衍射测量图像中恢复出的相位信息具有很大的重建误差; 对比而言, 本文所提出的自监督智能相位成像模型能够恢复出具有更多纹理细节、更少重建误差的相位图像。在两个合成数据上, 本文算法与 GS 算法恢复的相位图像相比, 峰值信噪比 (PSNR, peak signal-to-noise ratio) 分别提高了 11.38 dB 和 12.41 dB。图 2(c)、图 2(d) 对比了本文所提出的自监督智能相位成像模型在使用和不使用元学习训练时, 恢复出的相位图像及其误差图, 使用元学习优化初始参数的模型与使用随机初始参数的模型相比, 重建出的相位图像质量更高, 峰值信噪比分别提升了 6.88 dB 和 3 dB, 该结果表明元学习训练确实可以为所提网络模型提供一个更好的初始参数, 从而改进相位恢复的效率和成像效果。

所提算法中元学习训练优化的网络初始参数具有较好的泛化性, 在不同实验场景下均能显著提升网络的训练效率。本实验中可变的实验装置参数即衍射距离 d , 因此, 本文在 CeleA^[28]数据集上进行了仿真实验, 其中图像的分辨率为 178 px × 178 px。首先, 分别在衍射距离为 20.3 mm、22.3 mm、24.3 mm 的 3 种不同实验设置下进行元学习训练, 得到相应的网络初始参数, 然后在衍射距离为 22.3 mm 的实验数据上进行测试, 不同算法相位重建结果的收敛性对比如图 3 所示。图 3(b)~图 3(e)对比了无元学习训练与本文算法在不同设置下的实验结果, 实验结果表明不同实验装置下元学习优化的初始参数均能显著地提升 MLP 网络的优化速度和相位重建质量, 具有良好的泛化性。由于元学习优化的初始参数为网络训练提供了强先验信息, 本文方法迭代 100 次就可以得到较好的相位重建效果, 如图 3(g)、图 3(h)所示。本文算法与 GS 算法进行

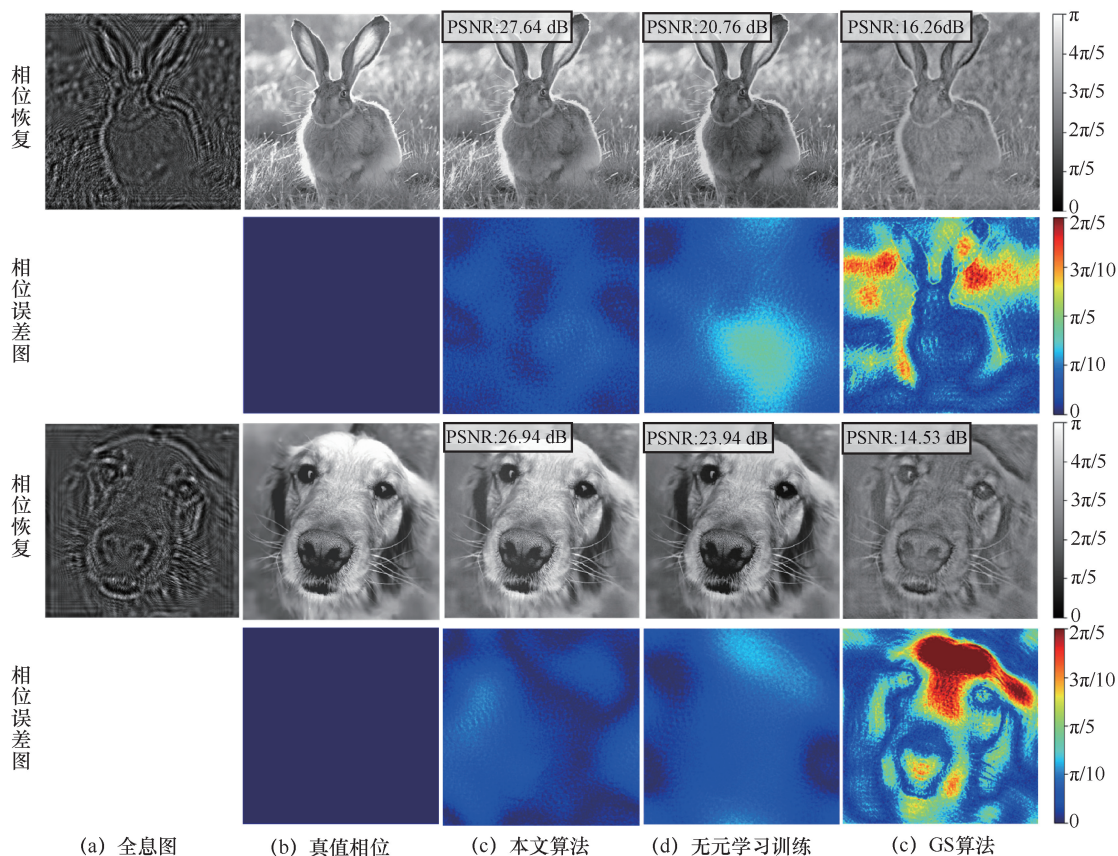


图 2 合成数据相位恢复结果对比

100 次迭代的时间分别为 0.76 s 和 0.68 s，虽然本文算法迭代速度略慢于 GS 算法，但相位重建质量远优于 GS 算法。无元学习方法进行 100 次迭代的重建效果相对较差，结构相似性 (SSIM, structural similarity) 低于本文算法，因此需要迭代更多次才能获得与本文算法相当的重建效果。

2.3 真实数据实验

在真实数据实验中，本文采用了 PhysenNet^[11]所提供的快照式无透镜成像数据进行测试。激光光照的中心波长为 632.8 nm，用于采集衍射图像的图像传感器像素尺寸为 8 μm，衍射距离为 22.3 mm。

首先，在 ImageNet 数据集中随机抽取 8 000 张图片构造一个快照式相位成像任务集。然后分别在衍射距离为 20.3 mm、22.3 mm、24.3 mm 的 3 种不同实验设置下进行元学习训练，得到相应的优化模型初始参数。最后，使用真实的快照式无透镜测量用于网络模型的训练和测试，真实数据相位恢复结果如图 4(a)所示。

可以看出，本文所提出的自监督智能相位成像算法能够从单张强度测量中恢复出高清晰度、高对比度的样本相位图像。相比之下，GS 算法恢复出的相位

图像夹杂着非常多的重建伪影，清晰度严重降低。此外，对比图 4(b)~图 4(e)可知，使用不同实验装置下元学习优化的初始参数来初始化模型，均可以显著减少相位图像的重建伪影，表明本文算法中元学习训练优化的网络初始参数具有良好的泛化性，这也与上述仿真实验的结论一致。图 4 中用红色虚线突出展示了 3 种方法恢复出相位图像中的一个线条轮廓区域，结果表明所提出的自监督智能相位成像算法比其他两种方法重建出的相位图像更加平滑，效果更好。

3 结束语

针对无透镜相位成像这一重要问题，本文提出了一种基于快照式无透镜感知的智能相位成像算法，将光学衍射传播理论引入隐式神经表示的设计中，并结合元学习方法初始化网络参数，实现了仅需要单张强度测量的高质量的相位图像重构。合成数据和真实数据上的实验结果均验证了所提算法在求解快照式相位成像逆问题中的高性能和鲁棒性。对于任何一个正向物理过程已知的成像问题，其逆过程求解均可以采用本文的模型自监督地求解该逆问题。进一步地，在仿真数据

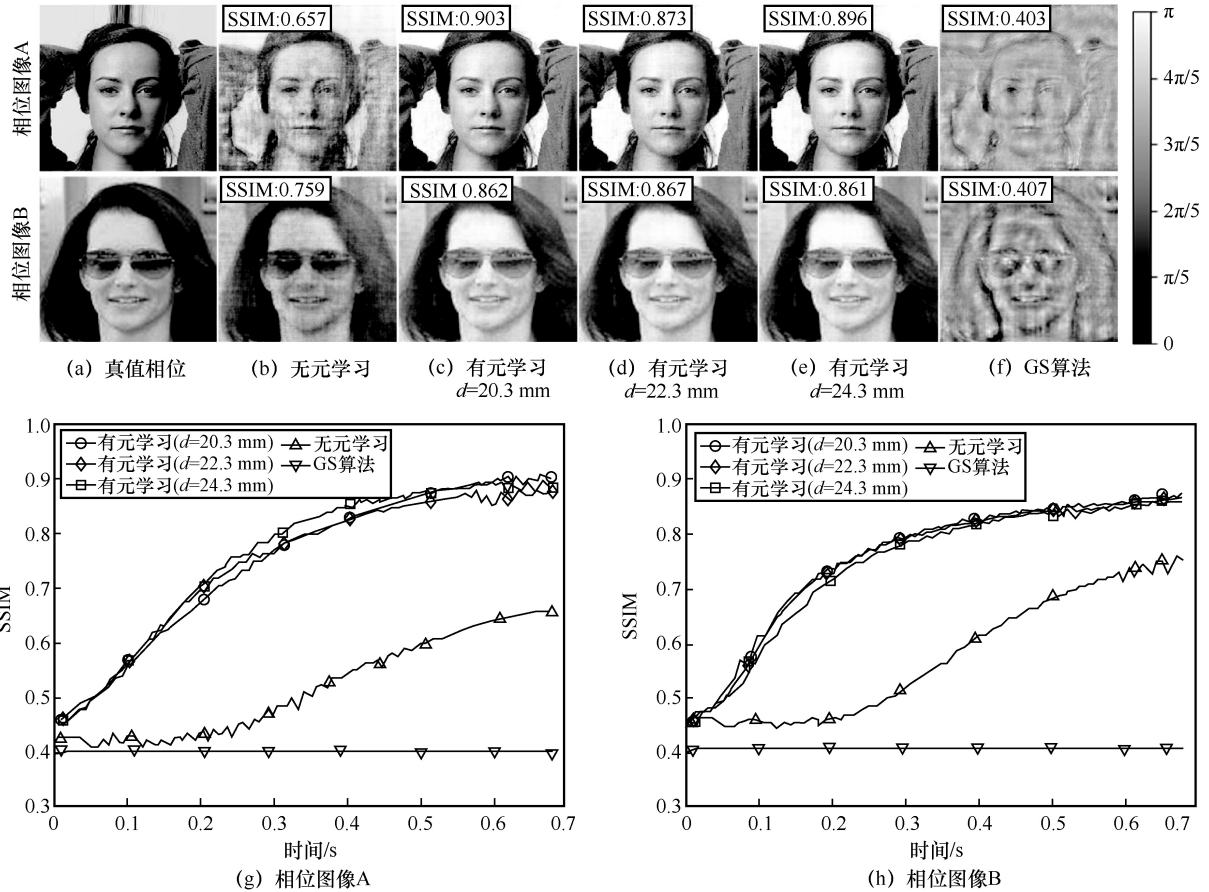


图 3 不同算法相位重建结果的收敛性对比




图 4 真实数据相位恢复结果

集上，利用元学习训练优化得到一个具有先验信息的模型初始参数，有效地提升了模型求解逆问题的性能。因此，在真实数据量较少的情形中，本文的模型提供了一种有效求解各种成像过程逆问题的新范式。

参考文献：


[1] REN Z B, XU Z M, LAM E Y M. End-to-end deep learning framework for digital holographic reconstruction[J]. *Advanced Photonics*, 2019, 1(1): 016004.
 [2] REN Z B, XU Z M, LAM E Y. Learning-based nonparametric autofocusing for digital holography[J]. *Optica*, 2018, 5(4): 337.
 [3] WANG H, LYU M, SITU G H. eHoloNet: a learning-based end-to-end approach for in-line digital holographic reconstruction[J]. *Optics Express*, 2018, 26(18): 22603.

[4] LYU M, WANG W, WANG H, et al. Deep-learning-based ghost imaging[J]. *Scientific Reports*, 2017, 7: 17865.
 [5] WANG F, WANG H, WANG H C, et al. Learning from simulation: an end-to-end deep-learning approach for computational ghost imaging[J]. *Optics Express*, 2019, 27(18): 25560.
 [6] GOY A, ARTHUR K, LI S, et al. Low photon count phase retrieval using deep learning[J]. *Physical Review Letters*, 2018, 121(24): 243902.
 [7] ZHANG G, GUAN T, SHEN Z Y, et al. Fast phase retrieval in off-axis digital holographic microscopy through deep learning[J]. *Optics Express*, 2018, 26(15): 19388.
 [8] MONAKHOVA K, TRAN V, KUO G, et al. Untrained networks for compressive lensless photography[J]. *Optics Express*, 2021, 29(13): 20913.
 [9] BARBASTATHIS G, OZCAN A, SITU G H. On the use of deep learning for computational imaging[J]. *Optica*, 2019, 6(8): 921.
 [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
 [11] WANG F, BIAN Y M, WANG H C, et al. Phase imaging with an un-

- trained neural network[J]. *Light: Science & Applications*, 2020(9): 77.
- [12] BOSTAN E, HECKEL R, CHEN M, et al. Deep phase decoder: self-calibrating phase microscopy with an untrained deep neural network[J]. *Optica*, 2020, 7(6): 559.
- [13] ZHANG X Y, WANG F, SITU G H. BlindNet: an untrained learning approach toward computational imaging with model uncertainty[J]. *Journal of Physics D: Applied Physics*, 2022, 55(3): 034001.
- [14] ZHU H, LIU Z, ZHOU Y, et al. DNF: diffractive neural field for lensless microscopic imaging[J]. *Optics Express*, 2022, 30(11): 18168.
- [15] ZHOU Y, WU J M, SUO J L, et al. Single-shot lensless imaging via simultaneous multi-angle LED illumination[J]. *Optics Express*, 2018, 26(17): 21418-21432.
- [16] SHECHTMAN Y, ELDAR Y C, COHEN O, et al. Phase retrieval with application to optical imaging: a contemporary overview[J]. *IEEE Signal Processing Magazine*, 2015, 32(3): 87-109.
- [17] FIENUP J R. Phase retrieval algorithms: a comparison[J]. *Applied Optics*, 1982, 21(15): 2758.
- [18] ZHOU Y, HUA X, ZHANG Z, et al. Wirtinger gradient descent optimization for reducing Gaussian noise in lensless microscopy[J]. *Optics and Lasers in Engineering*, 2020(134): 106131.
- [19] MAIDEN A, JOHNSON D, LI P. Further improvements to the ptychographical iterative engine[J]. *Optica*, 2017, 4(7): 736.
- [20] HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(9): 5149-5169.
- [21] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the 34th International Conference on Machine Learning - Volume 70. New York: ACM Press, 2017: 1126-1135.
- [22] TANCIK M, MILDENHALL B, WANG T, et al. Learned initializations for optimizing coordinate-based neural representations[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 2845-2854.
- [23] 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. Cham: Springer, 2015: 234-241.
- [24] RAHAMAN N, BARATIN A, ARPIT D, et al. On the spectral bias of neural networks[EB]. 2018.
- [25] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. NeRF: representing scenes as neural radiance fields for view synthesis[C]//European Conference on Computer Vision. Cham: Springer, 2020: 405-421.
- [26] KINGMA D P, BA J L. Adam: a method for stochastic optimization[J]. 3rd International Conference on Learning Representations, ICLR 2015-Conference Track Proceedings, 2015.
- [27] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C]//Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2009: 248-255.

- [28] LIU Z W, LUO P, WANG X G, et al. Deep learning face attributes in the wild[C]//Proceedings of 2015 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2016: 3730-3738.

[作者简介]



刘振（2002-），男，南京大学电子科学与工程学院与计算机科学与技术系联合培养硕士生，主要研究方向为隐式神经表示、无透镜成像等。



朱昊（1992-），男，博士，南京大学助理研究员，主要研究方向为物理启发神经网络和光场成像等。



周游（1990-），男，博士，南京大学助理教授、特聘研究员，主要研究方向为光学显微成像（无透镜显微成像、内窥显微成像、光场显微成像）和智能重构算法等。



马展（1981-），男，博士，南京大学教授，主要研究方向为类脑视频通信、视频编码、计算摄像、深度学习等。



曹汛（1983-），男，博士，南京大学教授，主要研究方向为图像和视频处理、光谱成像、计算摄像等。