

基于深度学习的单像素成像研究进展[‡]王琦^{1,2,3*}, 米佳帅¹¹东北大学信息科学与工程学院, 辽宁 沈阳 110819;²东北大学流程工业综合自动化国家重点实验室, 辽宁 沈阳 110819;³河北省微纳精密光学传感与检测技术重点实验室, 河北 秦皇岛 066004

摘要 单像素成像通过调制光场测量场景对单个像素探测器的强度响应来还原场景图像, 相比依赖阵列探测器捕捉图像信息的传统成像技术, 在低成本、宽光谱及特定应用场景下具有出色表现。该技术是一种由物理域转为计算域的新型成像方式, 因此众多研究在寻找高效的计算方式。由于神经网络在计算域中的强大学习能力, 深度学习技术已经广泛应用于单像素成像中并取得了显著进展。将深度学习单像素成像分为数据驱动式、物理驱动式及混合驱动式, 又在每个驱动模式下划分出神经网络用于“图像到图像”和神经网络用于“测量值到图像”两种成像方法。从 6 种角度综述基于深度学习的单像素成像方法的基本理论和典型案例, 并讨论了各类方法的优势与不足。最后对基于深度学习的单像素成像方法进行总结与展望, 有前景的应用包括高光谱成像、瞬态观测与目标检测。

关键词 单像素成像; 深度学习; 计算成像; 神经网络

中图分类号 O436

文献标志码 A

DOI: 10.3788/LOP232464

Research Progress of Single-Pixel Imaging Based on Deep Learning

Wang Qi^{1,2,3*}, Mi Jiashuai¹¹College of Information Science and Engineering, Northeastern University, Shenyang 110819, Liaoning, China;²State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, Liaoning, China;³Hebei Key Laboratory of Micro-Nano Precision Optical Sensing and Measurement Technology, Qinhuangdao 066004, Hebei, China

Abstract Single-pixel imaging reproduces scene images by modulating the light field to measure the intensity response of the scene with a single-pixel detector. Compared with traditional imaging techniques that rely on arrays of detectors to capture image information, single-pixel imaging excels in low-cost, broad-spectrum, and application-specific scenes. This technique is a novel imaging approach that shifts from the physical to the computational domain; hence, many studies are exploring efficient computational approaches. Owing to the powerful learning capability of neural networks in the computational domain, deep learning techniques have been extensively employed in single-pixel imaging and have made remarkable progress. In this paper, deep learning single-pixel imaging is categorized into three modes: data-driven, physical-driven, and hybrid-driven modes. Within each mode, neural networks are further categorized as “image-to-image” and “measurements-to-image” imaging methods. The basic theories and typical cases of single-pixel imaging methods based on deep learning are reviewed from six perspectives, and the advantages and shortcomings of each method are discussed. Finally, single-pixel imaging methods based on deep learning are summarized and discussed, and promising applications include hyperspectral imaging, transient observation, and target detection.

Key words single pixel imaging; deep learning; computational imaging; neural network

收稿日期: 2023-11-10; 修回日期: 2024-01-15; 录用日期: 2024-01-26; 网络首发日期: 2024-02-20

基金项目: 国家自然科学基金(62073068)、中央高校基本科研业务费专项资金(N2204019)、辽宁省应用基础研究计划项目(2023JH2/101300179)、流程工业综合自动化国家重点实验室研究基金(2018ZCX29)、河北省自然科学基金(F2020501040)、山东省自然科学基金(ZR2020MF108, ZR2020MD058)、沈阳市科技计划项目(23-407-3-01)

通信作者: *wangqi@ise.neu.edu.cn

‡本文为“第一届先进成像与信息处理会议暨 2023 中国光学学会全息与光信息处理专委会学术年会(AIIP2023)”全文投稿论文, 作者米佳帅为本届会议“优秀快闪口头报告”获奖人。

1 引 言

在追求高像素的主流成像方式中,单像素成像仅使用单个像素就能对物体场景进行高质量成像脱颖而出,这种特殊的成像方式又称为鬼成像和关联成像。它是利用多个不同的调制光场将二维或三维物体场景压缩编码成一维探测信号,再通过特定的算法从一维信号恢复出物体场景高维信息的新颖成像方式。这种特殊的成像机制在高光谱^[1-2]、遥感^[3-4]、三维成像^[5-8]、高速成像^[9]和显微成像^[10]等众多领域具有极大的应用潜力,可以解决传统成像技术无法解决的难题。

单像素成像起源于量子成像,1995年Pittman等^[11]利用纠缠双光子依靠量子纠缠特性实现了物体场景量子成像。所以早期量子纠缠被认为是实现量子成像的必要条件。随后众多研究人员先后使用赝热光实现了不具备量子纠缠性质的经典光源鬼成像^[12-15],对鬼成像的物理本质进行了更深入的探讨。直到2008年,Shapiro^[16]利用空间光调制器加载电脑预先生成的调制矩阵,省去了参考光路,实现了计算鬼成像,从而证明了鬼成像的本质是光场强度的二阶关联特性,并不依赖量子纠缠特性。同年单像素成像^[17]被提出,研究人员发现单像素成像与鬼成像的区别在于空间光调制器和成像物体在光路中的先后顺序不同,两者在成像机理、数学模型和重建策略上是完全相通的,因此二者本质属于同一种成像方式。

单像素成像的图像重构算法关系到图像的重构质量和重构效率^[18],二阶关联算法之后,为提升成像质量和缩短成像时间,差分鬼成像^[19]、归一化鬼成像^[20]、对应鬼成像^[21]等相继被提出,成像信噪比得到了一定程度的提高,但它们本质仍是关联算法。此外,信号处理中压缩感知算法^[22]的实现机理与单像素成像理论相一致,将压缩感知算法应用到单像素成像^[23]能够极大地提升图像的重建质量,进一步推动了单像素成像的发展。2015年傅里叶单像素成像^[24]将成像模型建立在频域上,利用频谱信息重构物体场景信息,使众多学者对傅里叶单像素成像技术展开研究。

近年来,随着人工智能机器学习的大范围普及以及深度学习在图像处理与信号处理中展现出的超强优势,众多研究人员将深度学习应用在计算成像中^[25],利用深度神经网络实现欠采样下的信息提取、图像重建与不适定逆问题求解。神经网络强大的表示学习能力和对复杂数据关系的建模能力为单像素成像提供了新的可能性和挑战。通过结合深度学习技术,众多研究人员以减少采样次数、提升重建质量和缩短成像时间为目的,利用单像素测量中的信息,通过神经网络快速、准确地还原出目标场景图像,从而为单像素成像领域带来了新的突破。

本文旨在探讨深度学习在单像素成像中的应用,首先介绍单像素成像的理论,其中包括三种经典成像

理论与深度学习成像理论;其次根据驱动方式的不同将深度学习单像素成像分为数据驱动式、物理驱动式及混合驱动式,又在每个驱动模式下根据神经网络所扮演的不同角色,将其划分出“图像到图像”和“测量值到图像”两种成像方法,介绍深度学习神经网络技术是如何应用到单像素成像中的;然后给出了不同成像方法的具体原理和典型研究进展,并对它们进行讨论对比;最后对本文进行总结,展望该技术的未来发展趋势。

2 基本理论

2.1 关联成像算法

鬼成像的原理示意图如图1所示。激光照射在旋转的毛玻璃上形成调制光场,再经过分束器分别作用在待测物体上和电荷耦合器件(CCD)相机上,物体透射或反射的总光强被单像素探测器收集。调制光场的空间信息 $P(x,y)$ 被CCD相机记录。计算鬼成像与单像素成像省去了参考光路,由空间光调制器(SLM)或数字微镜器件(DMD)形成调制光场。对于一个待测物体 $O(x,y)$,第 i 次探测的单像素光强值 S_i 可描述为

$$S_i = \iint P_i(x,y)O(x,y)dx dy, \quad (1)$$

经过 M 次测量,物体场景信息 O_{GI} 可以利用单像素探测值和调制光场的相关性^[16]得到:

$$O_{GI} = \frac{1}{M} \sum_{i=1}^M (P_i - \langle P_i \rangle)(S_i - \langle S_i \rangle). \quad (2)$$




图1 单像素成像原理

Fig. 1 Schematic of single-pixel imaging

2.2 压缩感知成像算法

单像素的成像过程从本质上讲是一个线性过程,将调制光场 P_i 表示为一维行向量,待测物体场景表示为一维列向量,单像素探测值还可描述为

$$S_i = P_i O, \quad (3)$$

M 次测量后,有

$$S = P O, \quad (4)$$

其中

$$S = [S_1, S_2, S_3, \dots, S_M]^T, \quad (5)$$

$$P = [P_1, P_2, P_3, \dots, P_M]^T. \quad (6)$$

根据式(4),直观的待测物体求解方法是

$$O = P^{-1} S. \quad (7)$$

但在实际的采样中,对于要恢复含有 N 个像素的场景图像,测量次数 M 往往小于 N ,调制矩阵 \mathbf{P} 无法求逆,因此式(4)是一个不适定问题。压缩感知是解决该问题的通用方法。压缩感知理论认为如果信号是稀疏的(某些域下只有少量非零值),那么它可以由远低于采样定理要求的采样点得到重建恢复,将 N 个像素值的图像信号在稀疏基下表示为

$$\mathbf{O}_{N \times 1} = \boldsymbol{\Psi}_{N \times N} \boldsymbol{\alpha}_{N \times 1}, \quad (8)$$

式中: $\boldsymbol{\Psi}$ 为稀疏矩阵; $\boldsymbol{\alpha}$ 为信号 \mathbf{O} 的稀疏表示。常用的稀疏变换有傅里叶变换、小波变换和离散余弦变换等。在此基础上进行 M 次欠采样可以表示为

$$\mathbf{S}_{M \times 1} = \mathbf{P}_{M \times N} \boldsymbol{\Psi}_{N \times N} \boldsymbol{\alpha}_{N \times 1}. \quad (9)$$

由于从低维信号 \mathbf{S} 恢复出高维信号 $\boldsymbol{\alpha}$ 是一个不适定问题,但因为 $\boldsymbol{\alpha}$ 只含有少量非零值,成功求解方程成为可能。稀疏信号 $\boldsymbol{\alpha}$ 可通过凸优化问题^[23]求解近似值:

$$\boldsymbol{\alpha} = \min \|\boldsymbol{\alpha}\|_1 \quad \text{s.t. } \mathbf{S} = \mathbf{P} * \boldsymbol{\Psi} * \boldsymbol{\alpha}, \quad (10)$$

得到图像在稀疏域下的稀疏信号后,再代入式(8)即可恢复出物体图像。

2.3 傅里叶成像算法

以上两种方法都是在空间域中对重构方法进行分析的。傅里叶单像素成像方法则是在频域上获取重建结果的,通过采集物体被不同空间频率结构光照射后的反射光信号,并借助相移算法获取包含物体所有傅里叶系数的完整频谱,再对其进行傅里叶逆转换,得到物体的重建图像。在光源调制上,傅里叶单像素成像以空间频率域条纹作为调制光场,可以描述为

$$P_{\phi}(x, y; f_x, f_y) = a + b \cos(2\pi f_x x + 2\pi f_y y + \phi), \quad (11)$$

式中: a 表示调制光场的直流分项; b 表示对比度; ϕ 表示初相位; f_x 和 f_y 表示空间频率。单像素的探测值可表示为

$$S_{\phi}(f_x, f_y) = \iint P_{\phi}(x, y; f_x, f_y) O(x, y) dx dy. \quad (12)$$

考虑实验中探测可能受到周围环境背景光噪声的影响,单像素探测器最终测得目标物体反射的总光强为

$$S_{\phi}^*(f_x, f_y) = B_n + k S_{\phi}(f_x, f_y), \quad (13)$$

式中: B_n 为背景光噪声; k 表示与探测器增益等有关的参量。根据四步相移法获取傅里叶系数即物体的频谱信息,

$$\begin{aligned} C(f_x, f_y) &= [S_0(f_x, f_y) - S_{\pi}(f_x, f_y)] + \\ & j[S_{\pi/2}(f_x, f_y) - S_{3\pi/2}(f_x, f_y)] = 2bk \cdot F\{O(x, y)\}, \end{aligned} \quad (14)$$

式中: F 表示傅里叶变换。对目标物体投射不同空间频率的结构光条纹,可以获得包含物体所有傅里叶系数的完整频谱,然后利用傅里叶逆变换即可以实现对目标物体的图像重建^[24],即

$$O_F = 1/2bk \cdot F^{-1}\{C(f_x, f_y)\}, \quad (15)$$

式中: F^{-1} 表示傅里叶逆变换。

2.4 深度学习成像算法

深度学习单像素成像方法的核心在于利用神经网络拟合单像素系统输入输出之间的关系,使用尽可能多的符合数据真实分布的数据对迭代出输入输出之间的映射函数。以 \mathbf{B} 作为网络的输入, \mathbf{A} 作为网络输出,神经网络从 \mathbf{B} 到 \mathbf{A} 的拟合过程可以描述为

$$\mathbf{A} = f_{\theta}(\mathbf{B}), \quad (16)$$

式中: f_{θ} 为含有大量权重参数 θ 的神经网络映射函数。神经网络以调整权重参数来最小化代价函数为目标获得一个从 \mathbf{B} 到 \mathbf{A} 的合适的映射关系。拟合映射函数时首先需要获取能够反映真实数据分布的训练数据集,其次搭建合适的网络模型拟合输入输出之间的映射关系,利用优化器训练网络权重参数以最小化代价函数。映射关系拟合完成后,只需要将真实重建过程的桶信号或传统算法恢复的噪声图像输入到映射关系中,就可以获得高质量的输出。

3 深度学习单像素成像的分类

在深度学习神经网络中,驱动方式通常指训练神经网络的方法。同一种网络结构可以使用不同的驱动方式进行训练,在深度学习单像素成像图像重建算法中驱动方式可以分为两大类:数据驱动式与物理驱动式。

数据驱动式主要从数据中学习先验知识来获得目标物体图像的最优解。具体来说,该方法利用神经网络拟合输入输出数据对,从而建立两者之间的映射关系,在重建图像时,只须将近似图像或单像素探测信号输入此映射关系即可,不需要进行额外的迭代运算,因此该方法可快速得到最佳结果。物理驱动式将单像素的成像物理过程融合到一个初始化的未经训练的神经网络中,通过物理模型的约束来优化神经网络权重参数,以生成目标物体图像。该方法在泛化性和可解释性方面具有巨大的优势。

图2展示了在相同的输入输出和相同的网络结构下两种方法的原理。图2(a)展示了数据驱动的单像素成像方法,神经网络的权重受输出图像与真实图像之间的损失约束,通过大量的数据集施加数据先验进行预训练,使得神经网络学习到单像素探测值与图像之间的映射关系。图2(b)展示了物理驱动的单像素成像方法,单像素的物理过程施加在网络的输出后,通过对调制光场与输出图像的再次作用,得到一系列模拟探测值。网络权重的约束不再需要数据集,而是依靠输出图像经过物理模型得到的模拟探测值与真实单像素探测值之间的损失所约束。二者的不同在于:前者需要大量的数据集进行预训练,在使用时直接将探测值输入到学习好的参数的网络中得到输出图像;而后者无需数据集进行预训练,但需要在使用时对输出图像用物理模型进行约束,再进行不断的迭代使得输出图像接近真实图像。

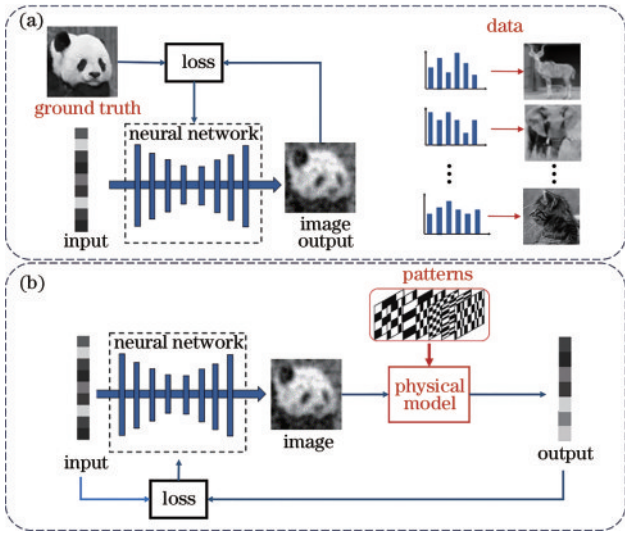


图 2 深度学习单像素成像中的驱动方式。(a)数据驱动式;(b)物理驱动式

Fig. 2 Driving styles in deep learning single pixel imaging. (a) Data-driven; (b) physically-driven

除了驱动方式的不同,根据神经网络扮演的角色不同,深度学习单像素成像图像重建算法可以分为用于“图像到图像”的神经网络和用于“测量值到图像”的神经网络两种应用方法。在“图像到图像”方法中,成像步骤中不舍弃传统单像素成像算法,利用关联或压缩感知等传统算法恢复出物体的噪声近似图,将此粗糙重建作为神经网络的输入进行图像增强以恢复出高质量的图像。此时神经网络在单像素成像中的应用更趋近于图像处理而与本身的成像算法无关。而“测量值到图像”方法中,神经网络将完全扮演成像算法这一角色,网络的输入为单像素探测值,利用大量的数据先验或物理先验,学习测量值与真实图像之间的联系特征,训练成一个由实验探测值到重建图像的端到端的图像重建网络。

两种方法的原理示意图如图 3 所示。图 3(a)神经网

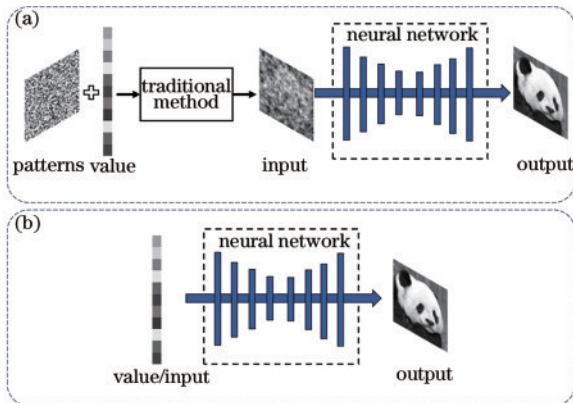


图 3 深度学习单像素成像中的神经网络作用。(a)“图像到图像”方法;(b)“测量值到图像”方法

Fig. 3 Deep learning of the role of neural networks in single pixel imaging. (a) “Image to image” method; (b) “measurements to image” method

络的输入为粗糙图像,是结合传统单像素成像算法的图像增强式神经网络方法。图 3(b)的输入为单像素探测值,相比用于“图像到图像”的神经网络,该方法不仅输入不同,整体的成像步骤也从两步成像缩减到一步成像。

4 数据驱动式深度学习单像素成像

4.1 神经网络用于“图像到图像”

深度学习在图像处理领域中的广泛应用影响了早期的深度学习单像素成像。由于传统算法的单像素成像在低采样率下的重构图像含有大量噪声,必须要对图像质量进行改善提高。一种直观的方法是将神经网络图像处理技术引入单像素成像,对传统方法所恢复出的高噪声图像进行图像增强与复原。

在该方法中,神经网络用于“图像到图像”。采用监督训练策略,利用大量噪声图像与真实图像作为训练数据集,学习二者之间的映射关系,完成由模糊图像向清晰图像的图像增强与复原。主要成像步骤分 3 步:首先利用关联算法、压缩感知或傅里叶等传统算法恢复出待测物体的粗略重建图像;其次搭建网络模型,构建尽可能多和尽可能广范围的粗略重建图像与真实清晰图像对应的数据集训练网络参数,学习对应关系;最后将要重构目标场景的粗略重建结果输入到已训练好的神经网络中,即可得到高质量的重构图像。网络学习和重构过程可描述为

$$f_{\theta^*} = \arg \min_{\theta} \| f_{\theta}(\mathbf{O}_T) - \mathbf{O}^* \|^2, \quad (17)$$

$$\mathbf{O}^* = f_{\theta^*}(\mathbf{O}_T^*), \quad (18)$$

式中: \mathbf{O}_T 和 \mathbf{O} 为数据集中对应的传统算法粗略重建图像与真实图像; f_{θ} 表示传统算法的重建图像; f_{θ^*} 和 \mathbf{O}_T^* 分别表示网络训练完成后,实际使用时的网络权重与网络输入; \mathbf{O}^* 为对深度学习图像处理得到的最终图像。

Lyu 等^[26]和 He 等^[27]首次使用该方法将深度学习应用在鬼成像中,如图 4 所示,分别使用全连接层和深度卷积神经网络提高了传统重构图像的质量,其中神经网络学习受噪声污染的图像的特征,并可以从新的受噪声污染的图像中预测低噪声图像,对传统关联成像得到的高噪声图像进行增强,极大地提升了图像的信噪比,得到了在低采样率下更快更准确的图像重构结果。实验结果如图 5 所示,可以看到增强后的成像质量要明显优于传统方法。

随后越来越多的研究人员利用该方法的思想,将不同的图像增强神经网络融入到单像素成像中,与不同的传统算法结合^[28-29],相继利用 U-net^[30]、自适应深度字典学习^[31]、双残差网络^[32]、生成对抗网络^[33]、注意力机制网络^[34]等多种神经网络训练数据的先验知识,解决了欠采样下的信息缺失问题,提高了单像素成像的图像重构质量;除此之外,还实现了超低采样率图像重建^[35]、实时单像素成像^[36]、运动物体成像^[37]、超分辨率成像^[38]、离焦问题成像^[39]、3D 重建^[40]、散射介质成像

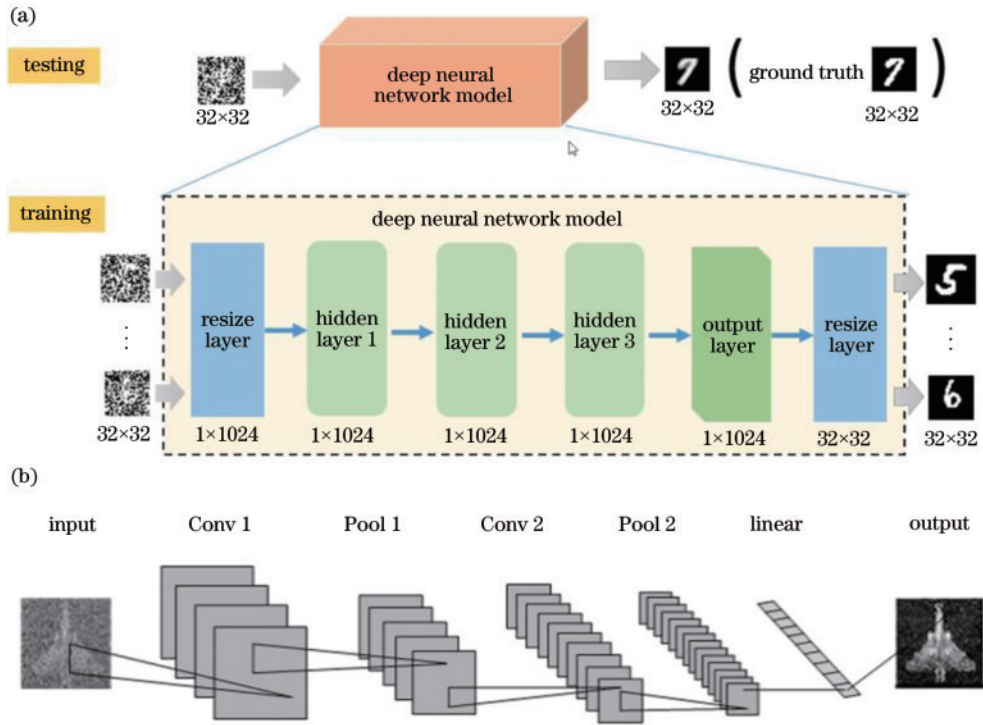


图 4 神经网络用于“图像到图像”式数据驱动深度学习在单像素成像中的应用^[26]。(a)全连接层神经网络；(b)卷积神经网络
 Fig. 4 Neural networks for “image-to-image” style data-driven deep learning in single pixel imaging^[26]. (a) Fully connected layer neural network; (b) convolutional neural network




图 5 神经网络用于“图像到图像”式数据驱动深度学习单像素成像的重建结果^[27]
 Fig. 5 Single pixel imaging reconstruction results of neural networks for “image-to-image” data-driven deep learning^[27]

和彩色图像重建^[41-44]等功能。

与以上以相同尺寸大小模糊图像作为输入的训练深度神经网络不同,2022年 Zhou 等^[45]利用阵列光场和单像素探测器实现了实时压缩鬼成像。该方法中的神经网络仍然用于“图像到图像”,但网络的输入不再是传统算法输出的模糊图像,而是阵列光场对应单像素探测值关联得到的压缩混叠图像。将大量的混叠图像和原始图像作为数据集训练神经网络,实现了混叠图像的图像复原。该方法在 3×3 倍压缩和 4×4 倍压缩下仍能很好地重建图像,理论上可以更高倍数压缩重建图像,实现更低数据量的实时成像。

4.2 神经网络用于“测量值到图像”

神经网络用于“测量值到图像”的方法由于网络输入是实验原始数据,网络输出是最终需要的结果,因此也被称为端到端神经网络。在该方法中,训练数据是单像素测量值和相应的真实图像而非传统算法恢复的粗略近似图像和相应的真实图像。神经网络的目标是将一系列一维测量值映射到二维图像空间,产生高分辨率的重建图像。相比神经网络用于“图像到图像”这一图像处理方法,这种方法由于减少了传统成像步骤,所以更高效快捷,重构方法可表示为

$$f_{\theta} = \arg \min \| f_{\theta}(S) - O \|^2, \quad (19)$$

$$O^* = f_{\theta^*}(S^*) \quad (20)$$

2019年 Wang 等^[46]率先提出了用于单像素成像的端到端神经网络,如图 6 所示,用模拟数据进行训练,直接从实验获得的一维测量信号重建二维图像,不需要传统成像算法与调制光场信息,训练完成后的神经网络可以用于从实验获得的桶信号中重建图像,值得注意的是这些测量信号是由仿真数据相同随机模式得到调制的。2020年 Zhu 等^[47]针对光照强度分布不确定的情况,提出了一种 Y 形结构的动态解码深度学习框架用于单像素成像。该方案在确定性和不确定性光照下都能很好工作,实验中编码样本的散斑的空间分布




图 6 端到端式深度学习单像素成像示意图^[46]

Fig. 6 Schematic of the end-to-end deep learning single-pixel imaging^[46]

可以与训练中模拟散斑的空间分布完全不同。

随后众多课题组开始利用神经网络直接从单像素探测器采集的数据中获得目标图像。例如,2020年 Wu 等^[48-49]实现了亚奈奎斯特采样率下的去噪神经网络单像素成像。Gao 等^[50]通过引入散射效应的干扰因子生成仿真数据,训练端到端神经网络,解决了不同散射路径下单像素成像重建问题。Hoshi 等^[51]将循环神经网络引入该方法,减少了内部参数量,提升了重构图像质量。2021年 Shang 等^[52]提出了一种两步训练深度学习框架,第一步直接学习逆模型,第二步优化输出图像。该方法不依赖于成像物理先验即传统方法,实验结果优于以往的一步式端到端神经网络单像素成像。这些方法极大地推动了单像素成像在实际环境中的应用^[53-55]。

4.3 “测量值到图像”的其他变式

单像素成像的采样阶段和重构阶段本质是高维信息的降维编码和低维信息的升维解码。受深度学习自编码器的启发,2018年 Higham 等^[56]将单像素成像的采样阶段融入神经网络优化调制光场。成像的具体过程如图 7 所示,与上述直接训练测量信号到图像映射关系这一重构方法不同,该方法在重构模块之前增加了采样策略优化模块。该模块可以采用编码器对调制光场进行优化,从而保证采样策略具有更高的效率,降低后续重构任务的复杂性。编码器被要求固定为一层与调制光场相同尺寸的卷积层。重构模块依旧采用“测量值到图像”的解码器结构,对目标的编码信号进行端到端的图像重构。在训练阶段,该方法将采样策略优化模块和重构模块连接在一起,进行“图像到图像”的神经网络训练。在测试或实际应用阶段,需要移除采样优化模块,仅将优化后的采样策略得到的一维单像素探测信号输入到重构模块中,即进行“测量值到图像”的神经网络重构,成像原理可表示为




图 7 自编码器学习采样模块与重构模块示意图^[56]

Fig. 7 Schematic of autoencoder learning sampling module and reconstruction module^[56]

$$\{f_{\theta}, P^*\} = \arg \min \|f_{\theta}(PO) - O\|^2, \quad (21)$$

$$O^* = f_{\theta}(S^*), \quad (22)$$

此时 P 不仅代表调制光场,同时也是网络结构中的第一层卷积层。

近些年相同的理念也应用在单光子成像^[57-58]、傅里叶散斑采样策略优化^[59]和与其他新型神经网络的融合中^[60-62]。

这种“测量值到图像”的端到端式数据驱动深度学习理念除了应用于单像素成像重建质量提升以外,还应用于“无图像”目标识别与场景分割中。在该方法中神经网络仍然是端到端的,但训练数据不再是单像素测量值与对应的原始图像标签,而是根据应用场景不同分别对应分类标签、分割图标签和定位坐标标签等。“无图像”单像素成像感知过程是:将待测场景编码为低维信号,只利用低复杂度的一维信号而非高维图像信息来恢复必要信息。这种方法可以最大化信号采集

效率,提高目标检测效率,突破硬件数据带宽采集、传输与处理的限制。

2020年 Zhang 等^[63]利用结构化照明和单像素检测直接获取目标特征,实现对快速运动物体的准确实时分类,方法示意图如图 8 所示。首先利用原始图像和分类标签训练卷积神经网络,学习目标特征,学习的首个卷积编码层用作结构化照明的结构化模式。目标分类可以通过将单像素检测器的一维光信号反馈给训练好的神经网络来实现。与此类似,还有诸多工作没有优化照明模式,而是使用特定的变换域完成了目标识别^[64-66]。2021年 Yang 等^[67]提出了一种基于深度学习的并发单像素成像、目标定位和分类方案,使用多任务学习,开发了一种新的损失函数,并创建了一个包含不同数量、不同大小的可能重叠对象的场景的数据集来训练网络模型,实现了并行目标成像、定位和分类。2022年 Bian 等^[68]将无图像单像素应用在多目标识别,利用卷积递归神经网络,采用双向长短期记忆递归神

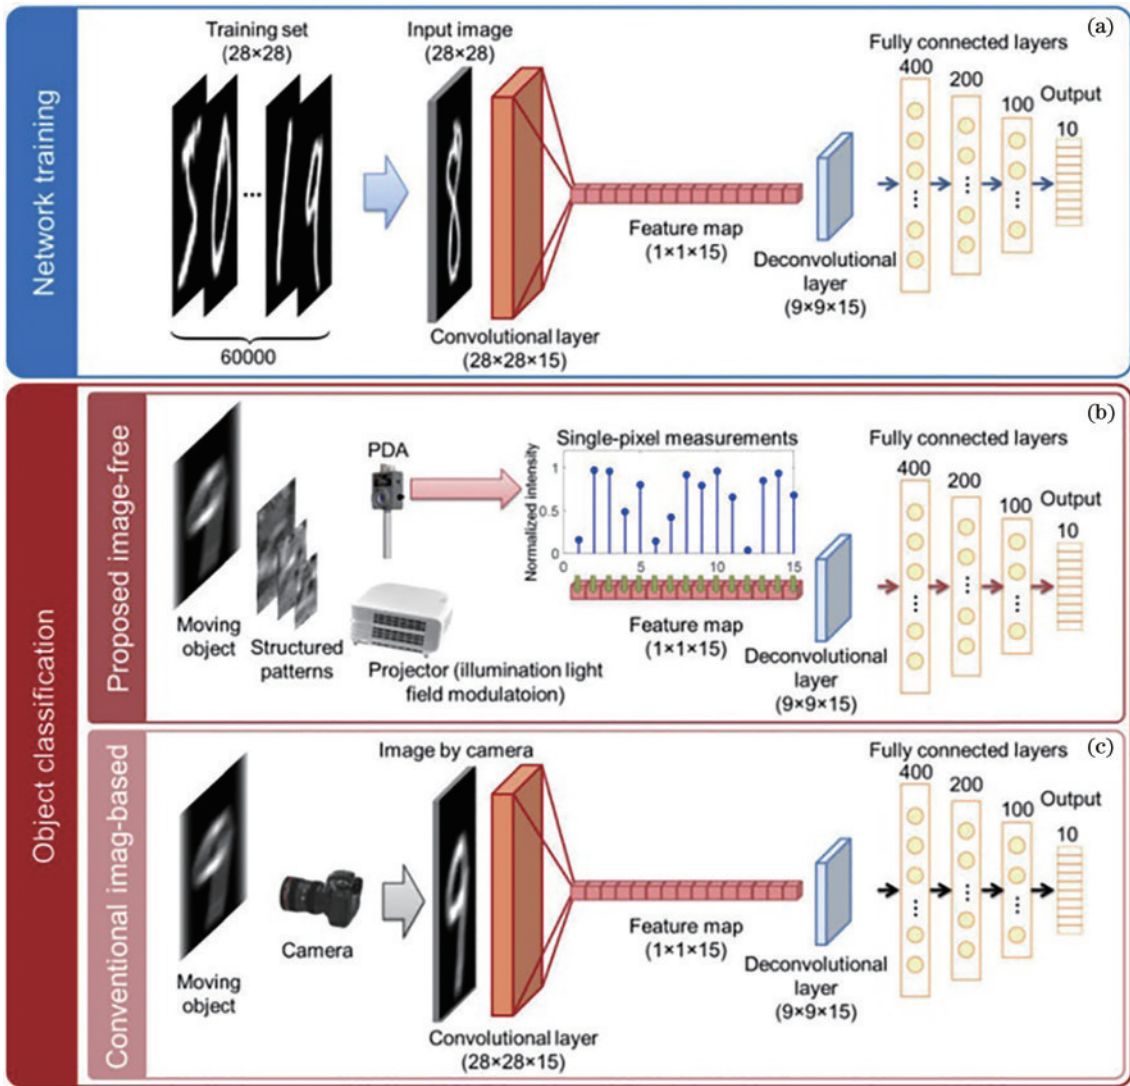


图 8 数据驱动深度学习单像素目标检测光电示意图^[63]。(a)网络训练;(b)提出的无图像方法;(c)传统基于图像的方法

Fig. 8 Photoelectric diagram of data-driven deep learning single-pixel target detection^[63]. (a) Network training; (b) proposed imaging-free method; (c) conventional image-based method

神经网络架构同时预测多个字符的分布,实现了车牌号的高准确率检测与识别。2023年,Liu等^[69]报告了一种无图像的单像素分割技术,利用数据驱动的神经网络直接从单像素测量中推断出分割映射。随着深度学习技术的发展,2023年Meng等^[70]设计的基于Transformer架构的神经网络能够直接从少量测量中实现高效率、抗干扰的复杂多目标检测。该架构网络不是简单地堆叠网络层,它可以更好地建模全局特征,增强网络对场景中目标的关注,从而提高了目标检测性能。这些应用都极大地推动了深度学习单像素成像在人工智能领域的应用。除此之外,深度学习“无图像”单像素探测技术还应用在激光制导^[71]、单光子雷达目标探测^[72]与太赫兹波段探测^[73-74]中,在动态目标传感应用中具有计算效率高、功耗低和其他计算资源有限平台下的实时应用等特点。

5 物理驱动式深度学习单像素成像

数据驱动式单像素成像中的神经网络都采用监督训练策略,因此一个优秀的神经网络需要一个大的训练集来优化它们的权重和偏差。这是非常耗时且受环境因素影响较大的,在许多实际应用中,往往无法获得完备的真实数据集而导致网络的泛化性不佳。同时由于机器学习的不可解释性,数据驱动神经网络的学习过程与学习到的拟合关系更像是一个黑盒子,输入到输出之间的映射关系也没有明确的数学模型。而单像素成像的物理过程可以用数学模型来描述,用该物理模型约束网络优化,通过神经网络和物理约束之间的相互作用自动优化网络参数,得到理想的输出。因此物理驱动式深度学习单像素成像可以在没有事先训练的情况下使用,从而消除了对数万个标记数据的需求,同时也给予了网络一定的可解释性。

这种思想起源于2018年Lempitsky等^[75]提出的深度图像先验,该框架使用未经训练的神经网络对潜在输入向量进行优化,重建受损图像。他们证明了一个适当设计的生成器网络架构本身对自然图像具有隐式偏见,因此可以用于解决不适定逆问题。类似的概念也被用于其他计算成像^[76-79]。

5.1 神经网络用于“图像到图像”

神经网络用于“图像到图像”物理驱动单像素成像方法的输入到输出是图像到图像的映射,未经训练的神经网络的优化过程是由物理模型驱动的。首先利用传统算法关联调制光场与单像素探测值得到物体的粗略近似;其次搭建一个未经训练的初始化的融入物理约束的网络模型;最后将粗略近似作为网络输入,通过物理模型的约束,不断迭代缩小输出模拟探测值与真实探测值的损失,更新权重,使得输出图像逐渐趋近真实目标场景。成像原理可表达为

$$f_{\theta^*} = \arg \min_{\theta} \| P f_{\theta}(\mathbf{O}_T) - \mathbf{S} \|^2, \quad (23)$$

$$\mathbf{O}^* = f_{\theta^*}(\mathbf{O}_T^*). \quad (24)$$

2022年Wang等^[80]提出了物理约束神经网络超远场鬼成像,成像步骤如图9所示。通过传统差分鬼成像关联调制光场与单像素探测值,得到物体的粗略近似;其次将差分鬼成像结果输入到未经训练的神经网络,然后将网络的输出作为对高质量重构图像的估计,再次进行式(4)所示的物理成像过程,得到模拟探测值;最后通过更新权重不断减小模拟探测值和真实探测值之间的损失,随着误差的减小,神经网络的输出也收敛到高质量的图像。与此类似的工作还有2023年Li等^[81]提出的基于未训练卷积自编码器网络的单像素物理模型驱动重构方法,其在成像质量上优于U-net。同年Wang等^[82]实现了无须训练神经网络的高光谱成像,在多波段均实现了高质量成像。




图9 物理约束神经网络单像素成像方法示意图^[80]

Fig. 9 Schematic of physically constrained neural network single-pixel imaging method^[80]

受物理约束的启发,2023年Chang等^[83]针对物理约束只能在测量域内使误差最小化,而在复杂和细节丰富的场景下,约束不充分会导致估计目标的非唯一性和成像质量不理想等问题,因此提出了双域约束的自监督学习单像素成像。在测量域约束下额外引入了变换约束提供隐式先验,避免测量约束的非唯一性,进一步提高重构质量。首先使用伪逆矩阵法得到物体的

粗略重建即神经网络的输入,神经网络受测量域约束得到物体的高质量重建;其次网络输出经过可逆变换(如图像移位和图像旋转)生成了一系列空间变换图像,实施变换约束。测量约束由真实测量值和模拟测量值之间的损失得到,变换约束由真实变换图像与模拟变换图像的损失得到。该方法扩大了物理模型驱动在单像素成像中的约束范围,进一步提升了图像重建

质量。

5.2 神经网络用于“测量值到图像”

神经网络用于“测量值到图像”物理驱动的深度学习单像素成像中,网络的输入为直接测量得到的一维探测信号,输出为二维目标图像。信号到图像的映射过程受物理模型约束,具体成像为

$$f_{\theta} = \arg \min \| P f_{\theta}(S) - S \|^2, \quad (25)$$

$$O^* = f_{\theta^*}(S^*). \quad (26)$$

2021 年 Liu 等^[84]提出了一种基于深度学习的未训练神经网络计算鬼成像方法。神经网络的输入仅仅是单像素探测器采集的一组一维光强值,通过网络与计算鬼成像过程的交互作用,神经网络可以自动优化生成恢复图像,首次实现了由物理驱动测量值直接到图像的成像过程,重建示意图如图 10 所示。一维信号预处理成与图像尺寸相同的二维平面,经过神经网络得到输出图像。网络参数是由最小化模拟探测值与真实探测值之间的损失约束的。由于该方法不具备数据先验,本质是迭代算法。所以网络的优化过程相对耗时,单次重建时间约为 5 min。相同的工作还有基于 URNet 的无须训练的单像素成像方法^[85],其在抗噪声和复杂图像恢复中具有良好表现。2024 年 Li 等^[86]将部件模型的自监督图像环路神经网络用于单像素成像,网络的输入是随机的二维信号,单像素探测器采集的一维信号作为标签,采用基于部分的模型,将图像特征划分为不同的部分,便于进行更细粒度的学习,从而在将随机输入的二维信号重建为二维物体图像时改善图像细节。同时网络生成的二维图像又作为后续迭代的输入,不断循环融合先验信息,保证低采样率下的成像质量。2023 年 Peng 等^[87]利用物理驱动端到端理念实现了在拐角、动态混浊水等复杂环境下高保真、高鲁棒的图像恢复,为通过复杂介质的自由空间传输单像素成像开辟了一条途径。




图 10 “测量值到图像”物理约束神经网络单像素成像方法示意图^[84]

Fig. 10 Schematic of “measurements to image” physical constrained neural network single-pixel imaging method^[84]

除此之外,2023 年本研究小组^[88]从另一个角度解释了单像素成像的前向物理模型,将待测目标场景作为调制光场到单像素探测值之间的映射函数。用神经网络拟合该物理过程,实现了单层卷积的物理驱动单像素成像,成像公式为

$$f_{\theta} = \arg \min \| f(P) - S \|^2, \quad (27)$$

$$O^* = f_{\theta^*}. \quad (28)$$

具体成像步骤如图 11 所示。该方法的网络结构完全按照前向物理模型设计,以一系列调制光场作为输入,经过单层卷积得到一系列模拟探测值,即无多余神经网络,直接进行式(4)这一前向物理过程。真实单像素探测值作为标签与模拟探测值作损失约束网络参数。特殊的是重构图像并非网络输出,而是网络中间的卷积核,随着输出更真实的检测值,卷积核参数愈发接近真实图像。由于该方法没有经过传统成像步骤,所以本质仍然是由测量值恢复二维图像。得益于简化的网络结构与正则化约束等,该方法在成像时间上优于其他物理驱动神经网络单像素成像方法。

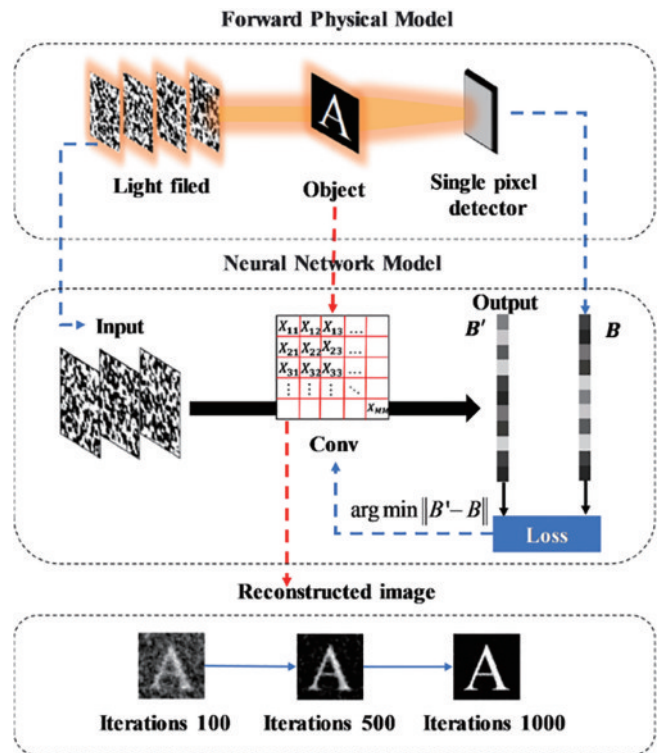


图 11 前向物理模型拟合神经网络单像素成像方法示意图^[88]
Fig. 11 Schematic of neural network single pixel imaging method fitting forward physical model^[88]

6 混合驱动式深度学习单像素成像

随着深度学习的发展,以及两种不同驱动方式所带来的不同优势,单纯使用数据驱动和物理驱动的深度学习技术虽然都可以解决不适定逆问题,但都有各自的缺陷。因此将二者结合共同应用在深度学习单像素成像的约束中,既可以引入数据先验补偿欠采样下的信息损失,又受物理约束增强了泛化性与可解释性。这样混合驱动的深度学习单像素成像方法的成像原理可表示为

$$f_{\theta} = \arg \min \| f_{\theta}(O_{TGI}) - O \|^2, \quad (29)$$

$$f_{\theta^*} = \arg \min \| P f_{\theta^*}(\mathbf{O}_{\text{TGI}}) - \mathbf{S} \|^2, \quad (30)$$

$$\mathbf{O}^* = f_{\theta^*}(\mathbf{O}_{\text{TGI}}), \quad (31)$$

$$f_{\theta^*} = \arg \min \| f_{\theta^*}(\mathbf{S}) - \mathbf{O} \|^2, \quad (32)$$

$$f_{\theta^*} = \arg \min \| P f_{\theta^*}(\mathbf{S}) - \mathbf{S} \|^2, \quad (33)$$

$$\mathbf{O}^* = f_{\theta^*}(\mathbf{S}), \quad (34)$$

式中: f_{θ^*} 表示数据驱动优化的网络参数; f_{θ^*} 表示物理驱动微调后的网络参数。式(29)~(31)表示神经网络用于“图像到图像”方法,网络输入为传统算法的重建近似。式(32)~(34)表示神经网络用于“测量值到图像”方法,网络输入为单像素探测值。

6.1 神经网络用于“图像到图像”

2021年 Wang 等^[89]首次将数据驱动与物理模型驱

动结合融入单像素成像,实现了物理增强的深度学习单像素成像,成像步骤如图 12 所示,主要分为两部分。首先利用数据先验优化卷积编码模块和深度神经网络图像增强模块。其中传统差分鬼成像将一维单像素探测值映射到二维粗略图像信号,实现采样策略的优化和初步粗糙图像的增强。其次利用物理模型驱动微调网络参数,通过拟合单像素测量值进一步增强图像。物理微调过程使得待测目标不必与用于训练数据先验的数据集相似。与传统的数据驱动深度学习和物理驱动优化方法相比,该方法在数据驱动和模型驱动算法之间建立了一座桥梁,允许人们在计算成像中的反问题求解中同时施加数据和物理先验,目前该方法已经成功应用在太赫兹成像中^[90]。

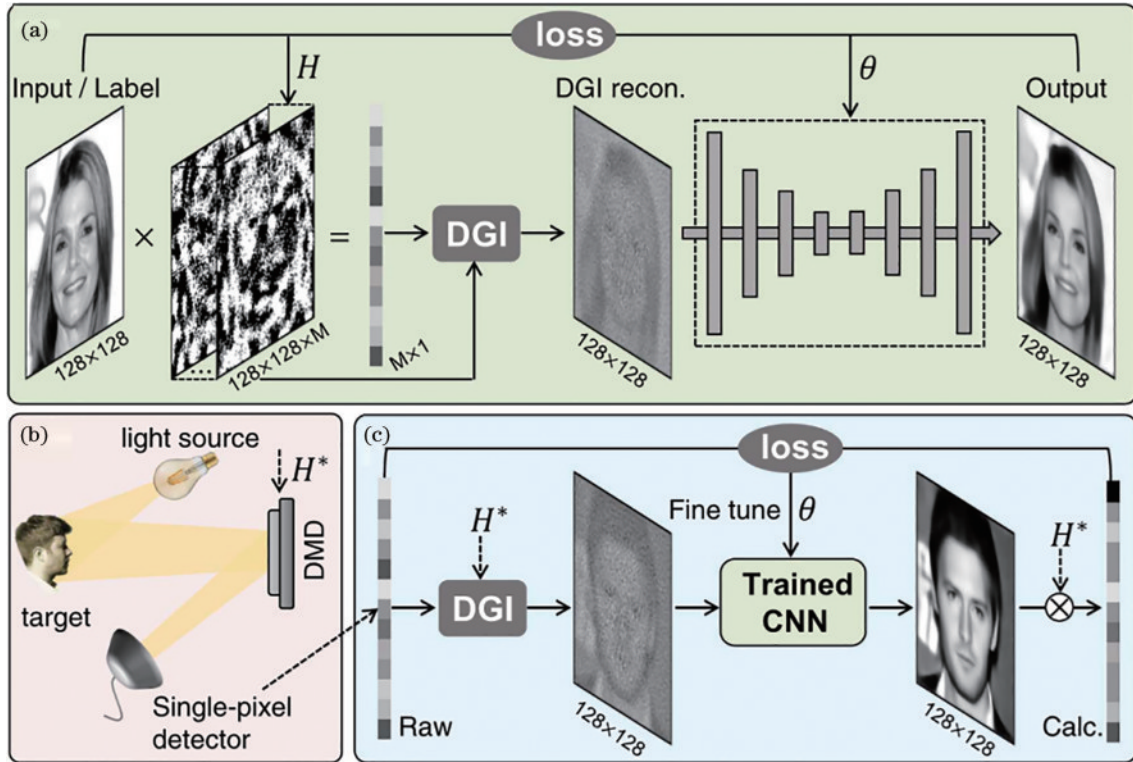


图 12 数据先验物理增强单像素成像方法示意图^[89]。(a)数据驱动网络的训练过程;(b)单像素成像系统;

(c)物理模型的驱动微调过程

Fig. 12 Schematic of data prior physical enhancement single-pixel imaging method^[89]. (a) Training process of data-driven network;

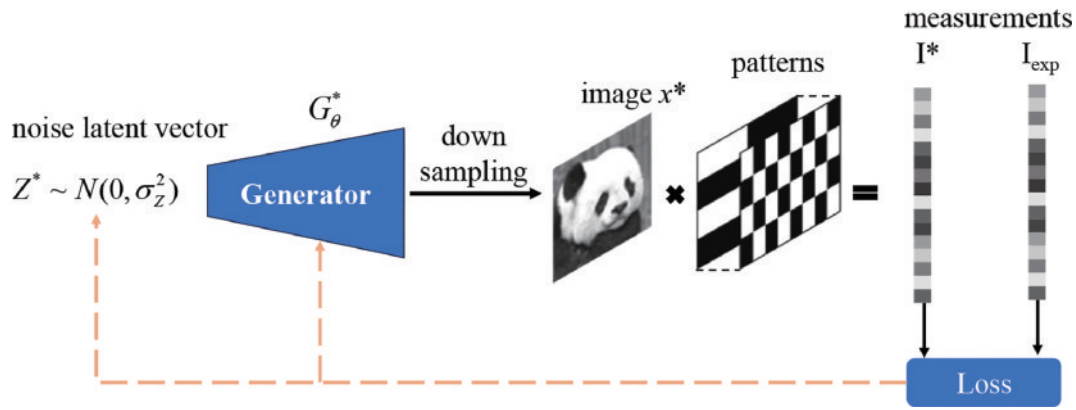
(b) single pixel imaging system; (c) physical model-drive fine tuning

6.2 神经网络用于“测量值到图像”

基于以上思想,2023年 Tian 等^[91]实现了端到端式,即神经网络用于“测量值到图像”的双驱动式深度学习单像素成像,舍弃了传统成像方法的物理信息层,而是将测量值直接由神经网络映射到图像。首先使用外部数据集训练该网络,学习大多数单像素重构的一般先验。最后在训练好的网络参数的基础上,利用物理模型约束和全变分正则化对网络进行微调,可以对每个测试对象学习特定的物理先验。该方法还可以与传统神经网络用于“测量值到图像”的数据驱动深度学习单像素成像算法结合,利用物理模型对经过数据先

验补充信息的图像进行增强,重构结果优于只使用数据先验的方法。

除此之外,2023年 Zhang 等^[92]将大模型微调技术应用在单像素成像中,成像步骤如图 13 所示。首先使用大模型预训练的参数施加数据先验,后使用物理模型进行微调,网络的输入为正态分布的噪声图,经过固定参数集的生成模型 BigGAN^[93]将输入向量生成图像;其次物理模型将生成图像转化为一维模拟信号;最后计算模拟信号与原始单像素探测强度之间的损失同时更新输入向量和生成器权重,随着不断迭代网络的输出,逐渐收敛到期望图像。在该方法中,生成器是

图 13 大模型生成先验物理增强单像素成像方法示意图^[92]Fig. 13 Schematic of the single-pixel imaging method of prior physical enhancement generated by large model^[92]

独立于成像系统的,因此可以对不同的成像模式使用相同的预训练模型,即一个网络可以解决许多问题,在其他计算成像问题中同样适用。

7 讨论与对比

单像素成像技术经历了光学角度、数学角度及神经网络角度的分析与发展。结合以上案例,深度学习技术已经被证明是一种有效求解不适定逆问题的方法,且在欠采样单像素成像技术中广泛应用。深度学习在单像素成像图像重构中的应用可以分为:数据驱动式“图像到图像”方法、数据驱动式“测量值到图像”方法、物理驱动式“图像到图像”方法、物理驱动式“测量值到图像”方法、混合驱动式“图像到图像”方法和混合驱动式“测量值到图像”方法。

不同方法的提出包含着不同的动机。最初的数据驱动式“图像到图像”方法对粗略图像进行图像处理增强旨在提高图像的重建质量,而数据驱动式“测量值到图像”方法省去了传统步骤,提高图像重建的速度。因此大多数实时深度学习单像素成像都以该理念出发,结合网络结构的优化,实现了实时视频帧的单像素成像和高检测效率的“无图像”目标识别等技术。对于所有物理驱动式与混合驱动式方法,目的在于避免数据集的制备、提高在未知场景的成像质量,因此在特殊场景和特殊波段下具有更大的应用前景。

不同的方法具有不同的应用场景与优势。首先对于驱动方式的不同,两种驱动方式在已知场景和未知场景表现不同,前期工作与后期重建的时间效率不同。具体表现如下。

数据驱动式方法需要大量的已知场景数据进行网络前期训练,所以该方法适合应用在已知场景范围内。同时该方法为非迭代算法,因此在重建时间上具有明显优势。但是该方法一个关键的问题是数据集的制备。由于单像素成像特殊的应用背景,实际探测场景往往是未知的,所以很难保证待测场景与训练数据具备相同特征,因此网络的泛化性难以保证,在未知场景

中的表现往往不佳。同时该方法前期训练的时间较长,通常高达数天或数周,是一种利用前期准备提高后期时间效率的方法。

物理驱动式算法无需待测场景的数据先验,可直接使用初始化的神经网络经过物理模型进行约束成像,避免了数据集的制备,节约了前期工作。但其本质是迭代算法,单次成像时间较长,通常为数十秒或数分钟。该方法的迭代次数与成像质量相关,因此选择迭代次数时需考虑质量与效率的需求。

将二者结合的双驱动式方法结合了二者的优点使图像质量得到大幅提升,但同时也不可避免地既需要前期数据准备也需要后期迭代微调。因此现有开源大模型通用网络的融入显得更有优势。

对于重建结果而言,以文献[91]为例,在相同的网络结构下不同驱动方式表现为不同的约束方法和不同的损失函数,最终呈现的成像质量不同,混合驱动式效果优于仅使用其中一种的方法。

其次对于神经网络所扮演的不同角色,两种成像方式在拟合深度、成像步骤与数据集制备等方面具有不同,具体表现如下。

在“图像到图像”神经网络方法中,由于方法属于图像处理方法,所以需要首先利用传统单像素成像方法重构带噪声的近似图像,然后将该近似量输入深度学习网络以增强图像。总体成像步骤呈现两步式。该方法的优点是用于计算机视觉任务的神经网络可以直接用于单像素成像。然而,这些方法往往试图拟合近似值和理想重建图像之间的浅层映射,忽略了内部成像模型。此外,利用传统方法产生模糊近似的过程需要额外的时间,这大大降低了成像效率,并且丢失了单像素成像测量空间中的大量特征信息。

“测量值到图像”方法属于端到端式方法,该方法省略了传统重建过程,直接将探测值映射到期望图像,提高了重建效率,但要求真实场景使用与训练数据相同的调制光场,在不确定性光照下无法得到有效重建。同时需要单独制作仅适用于单像素成像的探测值与真

实图像之间的数据集。在单像素成像中,需要多次不同模式的调制光场来采样一个物体或一个场景组成一组数据,通常需要数小时甚至数天的时间来实验性地收集数以万计的标记数据用于神经网络训练。这是不容易负担得起的。但后续将采样策略优化融入神经网络构成的自编码器解决了这一问题,因为自编码器的输入输出都为真实图像,所以网络训练的数据仅需要真实图像,从而省去了单维探测信号到多维图像信号的数据制作过程。

除以上驱动方式与神经网络的输入不同带来方法上的差异以外,在相同方法下,不同的网络结构也影响着深度学习单像素成像的性能。从目前的发展来看,具体表现为卷积网络优于全连接网络,深层网络优于浅层网络,跳跃连接优于直接连接等,但由于深度神经网络学习的不可解释性,选择结构时应尽可能保留信号特征。网络损失函数的选择也影响着网络性能,适当增加物理先验和全变分正则化有助于提升图像质量与减少网络的过拟合。

8 总结与展望

单像素成像依靠调制光场将二维场景信息编码为一维向量,最早通过强度关联、压缩感知和傅里叶等方法从一维向量中反演二维信息,相比传统成像方式,在许多领域中都具有明显优势。

从硬件设备上来看,单像素成像在没有可用的二维阵列探测器或者二维阵列探测器极其昂贵的场景下具有极大优势,因此逐渐在复杂环境与宽光谱波段成像领域中得到推广。同时,传统的阵列探测器成像系统无法完整捕获光场的多维信息,而单像素成像结合适当的重建算法能够还原场景的偏振和相位等信息,从而大大增强了光场信息的获取和利用。此外,单像素光电探测器通常具有高带宽和高时间分辨率,相较于阵列探测器,具备更高的速度和灵敏度等优势。因此,在高速成像和瞬态观测等场景中,单像素成像是一种无法被替代且成本低廉的选择。

从软件算法上来看,单像素成像是一种从物理域转为计算域的成像方式,成像效率受采样转换效率与图像重构效率的影响。因此在硬件资源确定的前提下,单像素成像在很大程度上依赖于合适的重构算法,以实现准确、高质量、高鲁棒与高速度的场景信息还原。不同应用可能需要不同的算法,因此算法的选择和优化是单像素成像领域的一个关键研究方向。

随着机器学习和图像处理等领域的发展,众多基于单像素成像的深度学习图像重建算法也逐渐涌现。从目前来看,深度学习单像素成像方法一直紧随机器学习神经网络的发展,从全连接网络到复杂结构网络、从浅层网络到深度神经网络、从人工神经元到大模型、从数据驱动到物理微调,都表现出了巨大优势。具体表现为更高质量的重构、更高速实时的成像效率和散

射介质、空间遥感和显微观测等更多复杂场景的适用性。但在目前众多深度学习单像素成像系统中,当采样次数、调制光场和成像大小等改变时,网络结构需要重新调整与训练。因此一个灵活的自适应的深度学习单像素成像方法尤为重要。

随着深度学习技术的不断改进,可以预期深度学习单像素成像将与更多的计算机最新领域模型相结合,持续挖掘深度学习潜力,拓宽广度增大神经网络形成大模型,实现规模量变到性能质变,完成深度学习单像素成像算法的突破,为应对不断复杂化的图像场景和更多干扰因素提供更有力的解决方案,使小视场生物医学成像、大视野空间遥感和高速自动驾驶目标检测等领域走向实际应用,开启一系列潜在的机遇和挑战。

参 考 文 献

- [1] Studer V, Bobin J, Chahid M, et al. Compressive fluorescence microscopy for biological and hyperspectral imaging[J]. Proceedings of the National Academy of Sciences of the United States of America, 2012, 109(26): E1679-E1687.
- [2] Olivieri L, Gongora J S T, Peters L, et al. Hyperspectral terahertz microscopy via nonlinear ghost imaging[J]. Optica, 2020, 7(2): 186-191.
- [3] Zhao C Q, Gong W L, Chen M L, et al. Ghost imaging lidar via sparsity constraints[J]. Applied Physics Letters, 2012, 101(14): 141123.
- [4] Gong W L, Zhao C Q, Yu H, et al. Three-dimensional ghost imaging lidar via sparsity constraint[J]. Scientific Reports, 2016, 6: 26133.
- [5] Sun B, Edgar M P, Bowman R, et al. 3D computational imaging with single-pixel detectors[J]. Science, 2013, 340(6134): 844-847.
- [6] Sun M J, Edgar M P, Gibson G M, et al. Single-pixel three-dimensional imaging with time-based depth resolution [J]. Nature Communications, 2016, 7: 12010.
- [7] Yang Z H, Li G H, Yan R T, et al. 3-D computational ghost imaging with extended depth of field for measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(12): 4906-4912.
- [8] 赵慧洁, 李宇曦, 姜宏志, 等. 复杂光照条件下的高精度三维成像技术[J]. 激光与光电子学进展, 2023, 60(8): 0811018.
Zhao H J, Li Y X, Jiang H Z, et al. High-precision 3D-imaging technology under complex illumination[J]. Laser & Optoelectronics Progress, 2023, 60(8): 0811018.
- [9] Jiang W J, Yin Y K, Jiao J P, et al. 2, 000, 000 fps 2D and 3D imaging of periodic or reproducible scenes with single-pixel detectors[J]. Photonics Research, 2022, 10(9): 2157-2164.
- [10] 李东哲, 周维帅, 黄素仪, 等. 基于单像素成像原理的多模式显微成像技术[J]. 光学学报, 2023, 43(21): 2111003.
Li D Z, Zhou W S, Huang S Y, et al. Multi-mode

- microscopic imaging technique based on single-pixel imaging principle[J]. *Acta Optica Sinica*, 2023, 43(21): 2111003.
- [11] Pittman T B, Shih Y H, Strekalov D V, et al. Optical imaging by means of two-photon quantum entanglement [J]. *Physical Review A*, 1995, 52(5): R3429-R3432.
- [12] Bennink R S, Bentley S J, Boyd R W. "Two-photon" coincidence imaging with a classical source[J]. *Physical Review Letters*, 2002, 89(11): 113601.
- [13] Gatti A, Brambilla E, Bache M, et al. Correlated imaging, quantum and classical[J]. *Physical Review A*, 2004, 70(1): 013802.
- [14] Valencia A, Scarcelli G, D'Angelo M, et al. Two-photon imaging with thermal light[J]. *Physical Review Letters*, 2005, 94(6): 063601.
- [15] Zhai Y H, Chen X H, Zhang D, et al. Two-photon interference with true thermal light[J]. *Physical Review A*, 2005, 72(4): 043805.
- [16] Shapiro J H. Computational ghost imaging[J]. *Physical Review A*, 2008, 78(6): 061802.
- [17] Duarte M F, Davenport M A, Takhar D, et al. Single-pixel imaging via compressive sampling[J]. *IEEE Signal Processing Magazine*, 2008, 25(2): 83-91.
- [18] 孙鸣捷, 闫崧明, 王思源. 鬼成像是和单像素成像技术中的重建算法[J]. *激光与光电子学进展*, 2022, 59(2): 0200001.
- Sun M J, Yan S M, Wang S Y. Reconstruction algorithms for ghost imaging and single-pixel imaging[J]. *Laser & Optoelectronics Progress*, 2022, 59(2): 0200001.
- [19] Ferri F, Magatti D, Lugiato L A, et al. Differential ghost imaging[J]. *Physical Review Letters*, 2010, 104(25): 253603.
- [20] Sun B Q, Welsh S S, Edgar M P, et al. Normalized ghost imaging[J]. *Optics Express*, 2012, 20(15): 16892-16901.
- [21] Li M F, Zhang Y R, Luo K H, et al. Time-correspondence differential ghost imaging[J]. *Physical Review A*, 2013, 87(3): 033813.
- [22] Donoho D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [23] Katz O, Bromberg Y, Silberberg Y. Compressive ghost imaging[J]. *Applied Physics Letters*, 2009, 95(13): 131110.
- [24] Zhang Z B, Ma X, Zhong J G. Single-pixel imaging by means of Fourier spectrum acquisition[J]. *Nature Communications*, 2015, 6: 6225.
- [25] Barbastathis G, Ozcan A, Situ G. On the use of deep learning for computational imaging[J]. *Optica*, 2019, 6(8): 921-943.
- [26] Lyu M, Wang W, Wang H, et al. Deep-learning-based ghost imaging[J]. *Scientific Reports*, 2017, 7(1): 17865.
- [27] He Y C, Wang G, Dong G X, et al. Ghost imaging based on deep learning[J]. *Scientific Reports*, 2018, 8(1): 6469.
- [28] Rizvi S, Cao J, Zhang K Y, et al. Improving imaging quality of real-time Fourier single-pixel imaging via deep learning[J]. *Sensors*, 2019, 19(19): 4190.
- [29] Zhang H, Duan D Y. Computational ghost imaging with compressed sensing based on a convolutional neural network[J]. *Chinese Optics Letters*, 2021, 19(10): 101101.
- [30] Shimobaba T, Endo Y, Nishitsuji T, et al. Computational ghost imaging using deep learning[J]. *Optics Communications*, 2018, 413: 147-151.
- [31] Zhai X, Cheng Z D, Liang Z Y, et al. Computational ghost imaging via adaptive deep dictionary learning[J]. *Applied Optics*, 2019, 58(31): 8471-8478.
- [32] Bian T, Yi Y X, Hu J L, et al. A residual-based deep learning approach for ghost imaging[J]. *Scientific Reports*, 2020, 10(1): 12149.
- [33] Zhang H, Xia Y J, Duan D Y. Computational ghost imaging with deep compressed sensing[J]. *Chinese Physics B*, 2021, 30(12): 124209.
- [34] Jiang P F, Liu J L, Wu L, et al. Fourier single pixel imaging reconstruction method based on the U-net and attention mechanism at a low sampling rate[J]. *Optics Express*, 2022, 30(11): 18638-18654.
- [35] Song H T, Nie X Y, Su H R, et al. 0.8% Nyquist computational ghost imaging via non-experimental deep learning[J]. *Optics Communications*, 2022, 520: 128450.
- [36] Rizvi S, Cao J, Zhang K Y, et al. DeepGhost: real-time computational ghost imaging via deep learning[J]. *Scientific Reports*, 2020, 10(1): 11400.
- [37] Hu H K, Sun S, Lin H Z, et al. Denoising ghost imaging under a small sampling rate via deep learning for tracking and imaging moving objects[J]. *Optics Express*, 2020, 28(25): 37284-37293.
- [38] Moodley C, Forbes A. Super-resolved quantum ghost imaging[J]. *Scientific Reports*, 2022, 12(1): 10346.
- [39] Rizvi S, Cao J, Hao Q. Deep learning based projector defocus compensation in single-pixel imaging[J]. *Optics Express*, 2020, 28(17): 25134-25148.
- [40] Ma X Y, Wang C X. 3D Single-pixel imaging with active sampling patterns and learning based reconstruction[J]. *Optics and Lasers in Engineering*, 2023, 163: 107447.
- [41] Ni Y, Zhou D F, Yuan S, et al. Color computational ghost imaging based on a generative adversarial network [J]. *Optics Letters*, 2021, 46(8): 1840-1843.
- [42] Liu H, Chen Y N, Zhang L, et al. Color ghost imaging through the scattering media based on A-cGAN[J]. *Optics Letters*, 2022, 47(3): 569-572.
- [43] Qu G, Meng X F, Yin Y K, et al. A demosaicing method for compressive color single-pixel imaging based on a generative adversarial network[J]. *Optics and Lasers in Engineering*, 2022, 155: 107053.
- [44] Huang W X, Wang F, Zhang X Y, et al. Learning-based adaptive under-sampling for Fourier single-pixel imaging [J]. *Optics Letters*, 2023, 48(11): 2985-2988.
- [45] Zhou C, Liu X, Feng Y S, et al. Real-time physical compression computational ghost imaging based on array spatial light field modulation and deep learning[J]. *Optics and Lasers in Engineering*, 2022, 156: 107101.
- [46] 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): 25560-25572.
- [47] Zhu R G, Yu H, Tan Z J, et al. Ghost imaging based on Y-net: a dynamic coding and decoding approach[J]. *Optics Express*, 2020, 28(12): 17556-17569.
- [48] Wu H, Wang R Z, Zhao G P, et al. Sub-Nyquist computational ghost imaging with deep learning[J]. *Optics Express*, 2020, 28(3): 3846-3853.
- [49] Wu H, Wang R Z, Zhao G P, et al. Deep-learning denoising computational ghost imaging[J]. *Optics and Lasers in Engineering*, 2020, 134: 106183.
- [50] Gao Z Q, Cheng X M, Chen K, et al. Computational ghost imaging in scattering media using simulation-based deep learning[J]. *IEEE Photonics Journal*, 2020, 12(5): 6803115.
- [51] Hoshi I, Shimobaba T, Kakue T, et al. Single-pixel imaging using a recurrent neural network combined with convolutional layers[J]. *Optics Express*, 2020, 28(23): 34069-34078.
- [52] Shang R B, Hoffer-Hawlik K, Wang F, et al. Two-step training deep learning framework for computational imaging without physics priors[J]. *Optics Express*, 2021, 29(10): 15239-15254.
- [53] Li F Q, Zhao M, Tian Z M, et al. Compressive ghost imaging through scattering media with deep learning[J]. *Optics Express*, 2020, 28(12): 17395-17408.
- [54] Yang X, Yu Z Y, Xu L, et al. Underwater ghost imaging based on generative adversarial networks with high imaging quality[J]. *Optics Express*, 2021, 29(18): 28388-28405.
- [55] Zhu Y L, She R B, Liu W Q, et al. Deep learning optimized terahertz single-pixel imaging[J]. *IEEE Transactions on Terahertz Science and Technology*, 2022, 12(2): 165-172.
- [56] Higham C F, Murray-Smith R, Padgett M J, et al. Deep learning for real-time single-pixel video[J]. *Scientific Reports*, 2018, 8(1): 2369.
- [57] Guan Y Q, Yan Q R, Yang S T, et al. Single photon counting compressive imaging based on a sampling and reconstruction integrated deep network[J]. *Optics Communications*, 2020, 459: 124923.
- [58] Gao W, Yan Q R, Zhou H L, et al. Single photon counting compressive imaging using a generative model optimized via sampling and transfer learning[J]. *Optics Express*, 2021, 29(4): 5552-5566.
- [59] Yang X, Jiang X D, Jiang P F, et al. S2O-FSPI: Fourier single pixel imaging via sampling strategy optimization[J]. *Optics & Laser Technology*, 2023, 166: 109651.
- [60] Tian Y, Fu Y, Zhang J. Local-enhanced transformer for single-pixel imaging[J]. *Optics Letters*, 2023, 48(10): 2635-2638.
- [61] Mur A L, Peyrin F, Ducros N. Deep expectation-maximization for single-pixel image reconstruction with signal-dependent noise[J]. *IEEE Transactions on Computational Imaging*, 2022, 8: 759-769.
- [62] Sun S D, Yan Q R, Zheng Y J, et al. Single pixel imaging based on generative adversarial network optimized with multiple prior information[J]. *IEEE Photonics Journal*, 2022, 14(4): 8538110.
- [63] Zhang Z B, Li X, Zheng S J, et al. Image-free classification of fast-moving objects using “learned” structured illumination and single-pixel detection[J]. *Optics Express*, 2020, 28(9): 13269-13278.
- [64] Bu T, Kumar S, Zhang H, et al. Single-pixel pattern recognition with coherent nonlinear optics[J]. *Optics Letters*, 2020, 45(24): 6771-6774.
- [65] Cao J N, Zuo Y H, Wang H H, et al. Single-pixel neural network object classification of sub-Nyquist ghost imaging[J]. *Applied Optics*, 2021, 60(29): 9180-9187.
- [66] Yao M H, Zheng S J, Hu Y H, et al. Single-pixel moving object classification with differential measuring in transform domain and deep learning[J]. *Photonics*, 2022, 9(3): 202.
- [67] Yang Z, Bai Y M, Sun L D, et al. SP-ILC: concurrent single-pixel imaging, object location, and classification by deep learning[J]. *Photonics*, 2021, 8(9): 400.
- [68] Bian L H, Wang H Y, Zhu C L, et al. Image-free multi-character recognition[J]. *Optics Letters*, 2022, 47(6): 1343-1346.
- [69] Liu H Y, Bian L H, Zhang J. Image-free single-pixel segmentation[J]. *Optics & Laser Technology*, 2023, 157: 108600.
- [70] Meng W W, Shi D F, Guo Z J, et al. Image-free multi-motion parameters measurement by single-pixel detection [J]. *Optics Communications*, 2023, 535: 129345.
- [71] Wang S Y, Li L J, Yu Z J, et al. Image-free target classification with semiactive laser detection system[J]. *IEEE Sensors Journal*, 2022, 22(23): 23088-23094.
- [72] Hong Y, Li Y X, Dai C, et al. Image-free target identification using a single-point single-photon LiDAR [J]. *Optics Express*, 2023, 31(19): 30390-30401.
- [73] Limbacher B, Schoenhuber S, Wenclawiak M, et al. Terahertz optical machine learning for object recognition [J]. *APL Photonics*, 2020, 5(12): 126103.
- [74] Yao J H, Jiao S M, Wang X K, et al. Fast terahertz image classification with a single-pixel detector[J]. *Optics Communications*, 2024, 550: 130016.
- [75] Lempitsky V, Vedaldi A, Ulyanov D. Deep image prior [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 9446-9454.
- [76] van Veen D, Jalal A, Soltanolkotabi M, et al. Compressed sensing with deep image prior and learned regularization[EB/OL]. (2018-06-17)[2023-11-09]. <https://arxiv.org/abs/1806.06438>.
- [77] Liu J M, Sun Y, Xu X J, et al. Image restoration using total variation regularized deep image prior[C]//2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), May 12-17, 2019, Brighton, UK. New York: IEEE Press, 2019: 7715-7719.
- [78] Zhou K C, Horstmeyer R. Diffraction tomography with a deep image prior[J]. *Optics Express*, 2020, 28(9): 12872-12896.

- [79] Wang F, Bian Y M, Wang H C, et al. Phase imaging with an untrained neural network[J]. *Light, Science & Applications*, 2020, 9: 77.
- [80] Wang F, Wang C L, Chen M L, et al. Far-field super-resolution ghost imaging with a deep neural network constraint[J]. *Light, Science & Applications*, 2022, 11: 1.
- [81] Li Z C, Huang J, Shi D F, et al. Single-pixel imaging with untrained convolutional autoencoder network[J]. *Optics & Laser Technology*, 2023, 167: 109710.
- [82] Wang C H, Li H Z, Bie S H, et al. Single-pixel hyperspectral imaging via an untrained convolutional neural network[J]. *Photonics*, 2023, 10(2): 224.
- [83] Chang X Y, Wu Z, Li D Y, et al. Self-supervised learning for single-pixel imaging via dual-domain constraints[J]. *Optics Letters*, 2023, 48(7): 1566-1569.
- [84] Liu S P, Meng X F, Yin Y K, et al. Computational ghost imaging based on an untrained neural network[J]. *Optics and Lasers in Engineering*, 2021, 147: 106744.
- [85] Li J S, Wu B, Liu T Y, et al. URNet: high-quality single-pixel imaging with untrained reconstruction network[J]. *Optics and Lasers in Engineering*, 2023, 166: 107580.
- [86] Li X L, Chen Y F, Tian T, et al. Part-based image-loop network for single-pixel imaging[J]. *Optics & Laser Technology*, 2024, 168: 109917.
- [87] Peng Y, Xiao Y, Chen W. High-fidelity and high-robustness free-space ghost transmission in complex media with coherent light source using physics-driven untrained neural network[J]. *Optics Express*, 2023, 31(19): 30735-30749.
- [88] Wang Q, Mi J S, Shi H R, et al. Ghost imaging by single-layer neural network based on forward physical model[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 4505310.
- [89] Wang F, Wang C L, Deng C J, et al. Single-pixel imaging using physics enhanced deep learning[J]. *Photonics Research*, 2021, 10(1): 104-110.
- [90] Deng Y Q, She R B, Liu W Q, et al. High-efficiency terahertz single-pixel imaging based on a physics-enhanced network[J]. *Optics Express*, 2023, 31(6): 10273-10286.
- [91] Tian Y, Fu Y, Zhang J. Joint supervised and unsupervised deep learning method for single-pixel imaging[J]. *Optics & Laser Technology*, 2023, 162: 109278.
- [92] Zhang X Y, Deng C J, Wang C L, et al. VGenNet: variable generative prior enhanced single pixel imaging[J]. *ACS Photonics*, 2023, 10(7): 2363-2373.
- [93] Brock A, Donahue J, Simonyan K. Large scale GAN training for high fidelity natural image synthesis[EB/OL]. (2018-09-28)[2023-11-09]. <https://arxiv.org/abs/1809.11096>.